

UNIVERSIDADE FEDERAL DO PARANÁ

FELIPE GABRIEL DE MELLO ELIAS

PREDIÇÃO ESPECTRAL PARA SISTEMAS DE RÁDIO COGNITIVO

CURITIBA PR

2021

FELIPE GABRIEL DE MELLO ELIAS

PREDIÇÃO ESPECTRAL PARA SISTEMAS DE RÁDIO COGNITIVO

Tese apresentada como requisito parcial à obtenção do grau de Doutor em Engenharia Elétrica no Programa de Pós-Graduação em Engenharia Elétrica, Setor de Tecnologia, da Universidade Federal do Paraná.

Área de concentração: *Engenharia Elétrica: Sistemas de Telecomunicações*.

Orientador: Evelio Martín García Fernández.

CURITIBA PR

2021

CATALOGAÇÃO NA FONTE – SIBI/UFPR

E42p

Elias, Felipe Gabriel de Mello

Predição espectral para sistemas de rádio cognitivo [recurso eletrônico]/ Felipe Gabriel de Mello Elias - Curitiba, 2021.

Tese apresentada no Programa de Pós-Graduação em Engenharia Elétrica, Setor de Tecnologia, da Universidade Federal do Paraná. Área de concentração: Engenharia Elétrica: Sistemas de Telecomunicações.
Orientador: Prof. Dr. Evelio Martín García Fernández.

1. Rádio cognitivo. 2. Sistema de comunicação sem fio. I. García Fernández, Evelio Martín. II. Título. III. Universidade Federal do Paraná.

CDD 621.3

Bibliotecária: Vilma Machado CRB9/1563

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA ELÉTRICA da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de Doutorado de **FELIPE GABRIEL DE MELLO ELIAS** intitulada: **Predição Espectral para Sistemas de Rádio Cognitivo**, sob orientação do Prof. Dr. EVELIO MARTÍN GARCÍA FERNÁNDEZ, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de doutor está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 25 de Fevereiro de 2021.

Assinatura Eletrônica

26/02/2021 09:44:43.0

EVELIO MARTÍN GARCÍA FERNÁNDEZ

Presidente da Banca Examinadora

Assinatura Eletrônica

26/02/2021 13:06:01.0

CARLOS MARCELO PEDROSO

Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica

26/02/2021 10:32:21.0

SAMUEL BARALDI MAFRA

Avaliador Externo (INSTITUTO NACIONAL DE TELECOMUNICAÇÕES)

Assinatura Eletrônica

26/02/2021 10:37:07.0

JOAO LUIZ REBELATTO

Avaliador Externo (UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ)

*Para Ana Paula, Penélope, Bernardo
e Angelina.*

AGRADECIMENTOS

Agradeço a Deus, pelo dom da vida.

Agradeço à minha esposa Ana Paula que me inspira sempre. A cada dia que passa parece que ficamos mais próximos. Obrigado pelos muitos momentos que estávamos estudando juntos, pelas palavras de incentivo, te amo!

Agradeço à minha filha Penélope, ao meu filho Bernardo e à minha filha Angelina. Obrigado por cederem o tempo para o papai estudar. Vocês são preciosos demais, amo vocês!

Agradeço aos meus pais por me incentivarem a sempre estudar e a ler. Obrigado por se doarem muitas vezes quando eu ainda era criança.

Agradeço ao meu orientador, prof. Dr. Evelio Martín García Fernández que caminha comigo desde a graduação. Obrigado pela dedicação e apoio.

Agradeço aos professores desta banca de defesa pelo tempo que se dedicaram para a leitura do trabalho e pelas contribuições que enriqueceram esta pesquisa.

Agradeço ao corpo docente do PPGE da UFPR pelos ensinamentos recebidos.

"Senhor meu Deus! Quantas maravilhas tens feito! Não se pode relatar os planos que preparaste para nós! Eu queria proclamá-los e anunciá-los, mas são por demais numerosos!"
Salmos 40:5

RESUMO

Este trabalho analisa a predição de espectro com múltiplos estados à frente para sistemas de rádio cognitivo. Um cenário baseado em *slot* é utilizado e a predição é baseada no algoritmo máquina de vetor de suporte que resulta em baixas taxas de erro de predição. O objetivo é identificar se a predição de espectro com múltiplos estados à frente possui ganhos em termos de taxa de transferência de rede e eficiência energética além de reduzir a quantidade de troca de canais. O tráfego do usuário primário é simulado por meio do software MATLAB usando a distribuição exponencial *on-off*, um exemplo de tráfego real também é analisado para verificar o desempenho do preditor. Novas aproximações para o detector de energia clássico são apresentadas com a finalidade de aprimorar o sensoriamento no caso da detecção com poucas amostras (SNR moderado). Expressões fechadas para a probabilidade de detecção, probabilidade de falso alarme, limiar constante e número de amostras são derivadas usando aproximações das distribuições qui-quadrado central e não central. Com a ajuda de simplificações, são apresentadas também novas expressões fechadas para a probabilidade de detecção sob canais AWGN com baixo SNR e canais com desvanecimento *Rayleigh*. O ciclo do usuário secundário foi modificado para realizar a predição com múltiplos estados. Com base nesse tipo de predição, um algoritmo que busca os canais com maior probabilidade de estarem desocupados por mais tempo é implementado permitindo uma redução na troca de canal de até 49%. Um aumento na taxa de transferência de aproximadamente 4% foi observado por meio da abordagem proposta. Os resultados também aumentaram a eficiência energética da rede em até 6%.

Palavras-chave: Radio Cognitivo. Predição Espectral. Comunicações Sem Fio.

ABSTRACT

This work analyzes the prediction of spectrum with multiple step ahead for cognitive radio systems. A slot-based scenario is used and the prediction is based on the support vector machine algorithm which results in low prediction error rates. The goal is to determine whether the spectrum prediction with multiple step ahead has gains in terms of network throughput, reduced channel switching and energy savings. The system model is simulated in software using an exponential on-off distribution for primary user traffic. New approaches for the classic energy detector are presented in order to improve the sensing in the case of detection with few samples. Closed-form expressions for the detection probability, false alarm probability and constant threshold are derived using approximations of the central and non-central chi-square distributions. With the help of simplifications, it is also presented new closed-form expressions for the probability of detection under AWGN channels and with Rayleigh fading. The secondary user cycle was modified for multi-step prediction. Based on this type of prediction, an algorithm that searches for the channels most likely to be unoccupied for longer period is implemented, allowing a reduction in channel switching of up to 49%. An increase in the throughput of approximately 4% was observed using the proposed approach. The results also increased the energy efficiency of the network up to 6%.

Keywords: Cognitive Radio. Spectral Prediction. Wireless Communications.

LISTA DE FIGURAS

1.1	Exemplo de uso inteligente do espectro.	18
2.1	Estágios do detector de energia implementado no SU.	24
2.2	Quadro simples (Liang et al., 2008) de operação do SU (SU-S) com duração T , dividido em duas etapas: (i) τ_S sensoriamento e (ii) $T - \tau_S$ transmissão ou espera.	27
2.3	Algoritmo executado pelo SU para sensoriamento simples. (a) Caso para apenas um canal. (b) Caso para múltiplos canais.	28
2.4	Etapas do Algoritmo de Aprendizagem de Máquina.	30
2.5	Divisão em quadros para um determinado canal, são indicados: o quadro atual, a janela de observação e a janela de predição.	31
2.6	Esquema simplista de mapeamento em dimensão superior da função <i>kernel</i>	33
3.1	Cenário 1 elaborado para análise do sensoriamento. Apenas um canal, um par de transceptores PU e um par de transceptores SU.	34
3.2	Curvas ROC teóricas e aproximadas para $N = 10$, $N = 20$, $N = 50$ e $N = 90$, com $\sigma_n = \sqrt{1/2}$ e $\gamma = -5$ dB.	41
3.3	Probabilidade medida de falso alarme (para $\hat{\lambda}_{th}^{CFAR-TLC}$, $\hat{\lambda}_{th}^{CFAR-Fi}$ e $\hat{\lambda}_{th}^{CFAR-WH}$) e medição da probabilidade de detecção de erros (para $\hat{\lambda}_{th}^{CDR-TLC}$, $\hat{\lambda}_{th}^{CDR-AA}$ e $\hat{\lambda}_{th}^{CDR-S}$) como função de $\hat{\gamma}$, utilizando $\hat{P}_f = 0,1$, $\hat{P}_d = 0,9$ e $\sigma_n = \sqrt{1/2}$	42
3.4	Comparação entre valores de projeto para N	44
3.5	Probabilidade de detecção teórica em função do número de amostras para um canal AWGN e um canal de desvanecimento de <i>Rayleigh</i> para a abordagem proposta e a literatura.	45
3.6	Probabilidade total de erro $P_f + P_{md}$ simulada, usando equações e aproximações originais, dependendo de (a) limiar de detecção e (b) número de amostras, usando valores de design diferentes \hat{P}_f , \hat{P}_d , $\sigma_n = 1$ e SNR = 0dB	46
3.7	Probabilidades medidas em função de γ para um número constante de amostras $N = 50$. As setas mostram as probabilidades medidas na região das probabilidades de projeto.	47
3.8	<i>Throughput</i> para o enlace do SU em função de γ para um número constante de amostras $N = 50$	48

4.1	Cenário 2 elaborado para análise da predição com múltiplos passos a frente onde diversos transceptores PU ocupam diferentes canais..	50
4.2	Tráfego com alta densidade $\rho = 0,7$, cerca de 70% dos quadros ocupados. (a) Transição entre estados mais frequente <i>on-off</i> com $\tau = 10$, e (b) taxa de transição menos frequente com $\tau = 30$	51
4.3	Tráfego real (a) 566,5 MHz e (b) 724,2 MHz.	52
4.4	Quadro de operação SU-P (Yang e Zhao, 2015), com duração T , dividido em três etapas: (i) τ_P predição, (ii) τ_S sensoriamento e (iii) $T - \tau_P - \tau_S$ transmissão ou espera..	53
4.5	Algoritmo executado pelo SU com emprego de predição e sensoriamento (Yang e Zhao, 2015)..	54
4.6	Exemplo para análise das expressões (4.6) e (4.7), composto por quatro canais e possíveis estados de predição, $F = 1$	56
4.7	Quadro de operação SU-M para predição com múltiplos passos à frente, com duração T , dividido em três etapas: (i) τ_P predição, (ii) τ_S sensoriamento e (iii) transmissão ou espera com intervalo $T - \tau_S$ ou $T - \tau_P - \tau_S$	57
4.8	Exemplo para análise das expressões (4.6) e (4.7), composto por três canais e possíveis estados de predição, $F = 2$	60
4.9	Um exemplo de escolha de canais pelo SU. Havendo vários canais desocupados a escolha mais lógica para o SU é continuar utilizando o mesmo canal..	63
4.10	O SU realiza trocas de canais que poderiam ter sido evitadas caso houvesse um planejamento antecipado.	64
4.11	Quadros modificados com a etapa de troca de canal incluída (a) Quadro básico SU-S. (b) Quadro com predição SU-P. (c) Quadro com predição para múltiplos estados SU-M..	65
4.12	probabilidade de predição errada, P_p^e , em função da quantidade de pontos futuros F , para diferentes tipos de algoritmos de aprendizagem de máquina.	71
4.13	Probabilidade de predição errada, P_p^e , em função da densidade de tráfego ρ , para diferentes valores de F . Figura gerada a partir do modelo exponencial <i>on-off</i> . . .	72
4.14	probabilidade de predição errada, P_p^e , utilizando dados empíricos, em função da densidade de tráfego ρ , para diferentes valores de F	73
4.15	Comparação da quantidade de troca de canal em função da densidade de tráfego, ρ , para os quadros SU-P' e SU-M'..	75
4.16	Comparação do <i>throughput</i> normalizado, R_{norm} , entre quadros avaliados supondo a troca de canal..	76

4.17	<i>Throughput</i> normalizado R_{Norm} da rede CR para o cenário AWGN com $F = 3$ e $F = 5$	77
4.18	<i>Throughput</i> da rede CR considerando o desvanecimento <i>Rayleigh</i> . São considerados os quadros SU-P e SU-M' com $F = \{3,5\}$	78
4.19	Eficiência energética EE em função da densidade de tráfego ρ para a rede CR para diversos quadros avaliados.	79

LISTA DE TABELAS

2.1	As distribuições de probabilidades do estado verdadeiro do canal e sensoriamento	29
3.1	Tabela de comparação dos resultados da simulação de <i>throughput</i> (<i>bit/uso do canal</i>)..	46
4.1	A distribuição de probabilidade do estado verdadeiro do canal e da predição (Yang e Zhao, 2015)	54
4.2	Probabilidades teóricas para sensoriamento, predição e estado verdadeiro do canal, supondo canal único ($N_C = 1$) e $F = 1$	55
4.3	Probabilidades teóricas para sensoriamento, predição e estado verdadeiro do canal, supondo múltiplos canais ($N_C > 1$) e $F = 1$ (Yang e Zhao, 2015).	57
4.4	Probabilidades teóricas para sensoriamento, predição e estado verdadeiro do canal, supondo canal único ($N_C = 1$) e $F = 2$	58
4.5	Probabilidades associadas a Figura 4.8	60
4.6	Probabilidades teóricas para sensoriamento, predição e estado verdadeiro do canal, supondo múltiplos canais ($N_C > 1$) e $F = 2$	61
4.7	Energia média e a eficiência energética para o quadro SU-S'.	69
4.8	Energia média e a eficiência energética para o quadro SU-P'.	70
4.9	Energia média e a eficiência energética para o quadro SU-M'.. . . .	70
4.10	Relação entre densidade de tráfego aproximado e f'_c das bandas avaliadas (Wellens e Mähönen, 2010).	74

LISTA DE ACRÔNIMOS

AWGN	<i>Additive White Gaussian Noise</i>
CCC	Canal de Controle Comum
CDF	<i>Cumulative Distribution Function</i>
CDR	<i>Constant Detection Rate</i>
CFAR	<i>Constant False Alarm Rate</i>
CR	<i>Cognitive Radio</i>
EE	Eficiência Energética
PDF	<i>Probability Density Function</i>
PU	<i>Primary User</i>
ROC	<i>Receiver Operating characteristic Curve</i>
SNR	<i>Signal-to-Noise Ratio</i>
SU	<i>Secondary User</i>
SVM	<i>Support Vector Machines</i>
SVR	<i>Support Vector Regression</i>
TLC	Teorema do Limite Central

LISTA DE SÍMBOLOS

λ_{th}	limiar de detecção do detector de energia
Λ	estatística de teste do detector de energia
γ	relação sinal ruído entre PU e SU
γ_S	relação sinal ruído entre SU e SU
σ_n^2	variância do ruído
σ_x^2	variância do sinal do PU
σ_s^2	variância do sinal do SU
h	ganho do canal, enlace PU-SU
h'	ganho do canal, enlace SU-SU
P_f	probabilidade de falso alarme
P_d	probabilidade de detecção
P_{md}	probabilidade de detecção errada
P_e	probabilidade total de erro
χ_v^2	distribuição qui-quadrado central
$f_{\Lambda \mathbf{H}_0}(\lambda)$	função densidade de probabilidade da χ_v^2
$F_{\Lambda \mathbf{H}_0}(\lambda)$	função densidade acumulada da χ_v^2
$\chi_v'^2$	distribuição qui-quadrado não central
$f_{\Lambda \mathbf{H}_1}(\lambda)$	função densidade de probabilidade da $\chi_v'^2$
$F_{\Lambda \mathbf{H}_1}(\lambda)$	função densidade acumulada da $\chi_v'^2$
ν	graus de liberdade de χ_v^2 e $\chi_v'^2$
φ	parâmetro de não centralidade de $\chi_v'^2$
N	quantidade de amostras do detector de energia
N^*	quantidade de amostras de projeto (TLC)
\hat{N}	quantidade de amostras de projeto (proposto)
f_S	frequência de amostragem
τ_S	intervalo de sensoriamento
τ_P	intervalo de predição
τ_{CS}	intervalo de troca de canal
T	intervalo do quadro do SU
SU-S	Quadro do SU com etapa de sensoriamento
SU-P	Quadro do SU com etapa de predição e sensoriamento
SU-M	Quadro do SU com etapa de predição de múltiplos estados e sensoriamento
SU-S'	Quadro do SU com etapa de sensoriamento e troca de canal

SU-P'	Quadro do SU com etapa de predição, sensoriamento e troca de canal
SU-M'	Quadro do SU com etapa de predição de múltiplos estados, sensoriamento e troca de canal
α	fator de ajuste de <i>throughput</i>
P_p^e	probabilidade de predição errada
N_C	quantidade de canais na rede CR
η	determinado canal na rede CR
s_i	quadro atual sendo avaliado
L	janela de observação
F	janela de predição
Tr	quantidade de quadros na fase de treinamento
Sl	quantidade de quadros na fase de validação
\hat{u}	número de quadros ociosos sequenciais subsequentes
$\phi(x)$	função <i>kernel</i>
ε	valor limite da função de regressão
\bar{P}_d	probabilidade média de detecção
$f^{SNR}(\gamma)$	distribuição do SNR do canal
μ_0	média da distribuição exponencial para período de desocupação
μ_1	média da distribuição exponencial para período de ocupação
$f_{\mu_0}(t_{off})$	função de distribuição exponencial para desocupação
$f_{\mu_1}(t_{on})$	função de distribuição exponencial para ocupação
τ	taxa de alteração dos padrões de ocupação
ρ	densidade de tráfego
θ	quantidade de estados preditos desocupados
κ	quantidade de estados preditos ocupados
Ψ	quantidade de probabilidades diferentes de predição, sensoriamento e estado verdadeiro na análise com múltiplos estados à frente
f_a	faixa de frequência para amostragem empírica
f_c	frequência central para amostragem empírica
$P_{0(s)}$	probabilidade da predição de classificar um canal como ocioso
$P_{1(s)}$	probabilidade da predição de classificar um canal como ocupado
$P_{i(l)}$	i-ésima probabilidade da predição com múltiplos estados futuros para um canal
$P_{i[q N_C]}$	i-ésima probabilidade do quadro SU-P para sensoreamento, predição e estado verdadeiro do canal para N_C canais
$P_{i[r N_C]}$	i-ésima probabilidade do quadro SU-M para sensoreamento, predição e estado verdadeiro do canal para N_C canais
n_C	quantidade de canais preditos ociosos

n_C^*	quantidade de canais a serem sensoriados definido no algoritmo
η^*	determinado canal na rede CR que pertence aos canais preditos ociosos e pertence a n_C^*
\mathcal{E}	energia média utilizada para transmissão
\mathcal{P}_T	potência do intervalo de transmissão
\mathcal{P}_S	potência do intervalo de sensoriamento
\mathcal{P}_{CS}	potência do intervalo de troca de canal
\mathcal{P}_P	potência do intervalo de predição
ι	potência de sensoriamento para uma largura de banda unitária
W	largura de banda
p_T	probabilidade de transmissão dos quadros sem necessidade de troca de canal
p_{CS}	probabilidade de transmissão dos quadros com troca de canal

SUMÁRIO

1	INTRODUÇÃO	18
1.1	ESTADO DA ARTE	19
1.1.1	Sensoriamento	19
1.1.2	Predição	20
1.2	MOTIVAÇÃO E JUSTIFICATIVA	21
1.3	OBJETIVOS	22
1.4	CONTRIBUIÇÕES CIENTÍFICAS	23
1.5	ESTRUTURA DO DOCUMENTO.	23
2	FUNDAMENTAÇÃO TEÓRICA.	24
2.1	DETECTOR DE ENERGIA	24
2.2	PREDIÇÃO	29
2.2.1	Máquinas de Vetor de Suporte	32
3	APRIMORAMENTOS NO SENSORIAMENTO.	34
3.1	MODELO DO SISTEMA	34
3.2	APROXIMAÇÕES PARA OTIMIZAÇÃO NA ETAPA DE SENSORIAMENTO	35
3.2.1	Análise para alto SNR	35
3.2.2	Análise para baixo SNR.	39
3.3	RESULTADOS	40
4	APRIMORAMENTOS NA PREDIÇÃO.	49
4.1	MODELO DO SISTEMA	49
4.1.1	Modelagem de Tráfego	49
4.2	QUADRO COM PREDIÇÃO E SENSORIAMENTO	53
4.2.1	Análise para um estado à frente.	53
4.2.2	Análise para múltiplos passos à frente	56
4.3	AGENDAMENTO DE CANAIS	63
4.3.1	Agendamento por quantidade de canais ociosos	64
4.4	ANÁLISE DA EFICIÊNCIA ENERGÉTICA	69
4.5	RESULTADOS	70

5	CONSIDERAÇÕES FINAIS	82
5.1	TRABALHOS FUTUROS	83
	REFERÊNCIAS	86

1 INTRODUÇÃO

Os benefícios das comunicações sem fio despertaram um aumento na utilização dessa tecnologia de forma sem precedentes nos últimos anos (Ding et al., 2015). Uma das consequências desse aumento é a dinâmica do uso do espectro no qual mais usuários devem compartilhar um espectro de frequências limitado. Nesse contexto, o Rádio Cognitivo (CR, do inglês *Cognitive Radio*) (Mitola e Maguire, 1999) surgiu como um novo modelo para a utilização do espectro de forma mais eficiente. Esse novo paradigma define os usuários nativos de determinada frequência como usuários primários (PUs, do inglês: *Primary Users*), enquanto que dispositivos que utilizam o espectro de maneira oportunística são conhecidos como usuários secundários (SUs, do inglês: *Secondary Users*).

Dispositivos cognitivos podem realizar o compartilhamento do espectro com o PU por meio de três protocolos: *underlay*, *overlay* e *interweave* (Goldsmith, 2005). Nas duas primeiras abordagens as relações de transmissão do PU e do SU são exploradas de forma concomitante em relação ao tempo. Na abordagem *interweave*, o SU não tem conhecimento prévio do sinal do PU ou do estado do canal e realiza sensoriamento espectral para examinar o estado atual. Isso permite que o SU realize a transmissão caso o estado do PU se encontre ocioso. A Figura 1.1 mostra diferentes canais que ocupam porções de banda em função do tempo. Esse exemplo ilustra um cenário no qual o SU ocupa diferentes canais de acordo com a oportunidade.




Figura 1.1: Exemplo de uso inteligente do espectro.

Nesse contexto, o SU deve realizar o sensoriamento de espectro de forma confiável e robusta para que não venha ocupar um canal em uso. A elaboração de técnicas confiáveis para o sensoriamento de espectro é um assunto fundamental para o projeto de redes de CR. No entanto, apesar de ser possível para um SU pesquisar aleatoriamente canais inativos, esse procedimento

é caro em termos de energia e tempo de sensoriamento (Jain e Goel, 2017). A dinâmica de uso dos canais apesar de possuir certo grau de aleatoriedade, pode ser avaliada com elevada previsibilidade (Ding et al., 2015). Diante disso é válido utilizar esquemas de análise de padrões para prever o uso do espectro.

1.1 ESTADO DA ARTE

1.1.1 Sensoriamento

O sensoriamento espectral pode ser implementado por vários métodos encontrados na literatura, tais como detecção de energia, detecção baseada em filtro casado, detecção de recurso ciclo estacionário, entre outras (Murty, 2018). No entanto, o detector de energia (Urkowitz, 1967) é a técnica mais simples e eficaz pois não requer conhecimento das propriedades do sinal transmitido, do estado do canal ou mesmo do esquema de modulação utilizado, gerando em sua saída um valor proporcional à energia do sinal recebido. O detector de energia possui seu desempenho medido em termos de probabilidades de detecção e de falso alarme. Por meio desses parâmetros é possível garantir a proteção da transmissão do PU.

O PU possui prioridade no uso da banda, assim o SU pode implementar um esquema básico de ciclo de monitoramento (quadro do SU) que é executado de forma periódica e dividido em dois intervalos (Liang et al., 2008). No primeiro intervalo do quadro, o SU realiza o sensoriamento e com base nesse resultado ele pode efetuar duas ações no segundo intervalo: realizar a transmissão efetiva de informação ou entrar em modo de espera. A literatura apresenta o tempo ótimo para sensoriamento com base no detector de energia que maximiza o *throughput* da rede (Liang et al., 2008). Nesse caso foi utilizado a aproximação Gaussiana, ou abordagem do Teorema do Limite Central (TLC), ao assumir um grande número de amostras para realizar o sensoriamento (Atapattu et al., 2014).

A detecção de energia com a análise da duração ótima do sensoriamento foi estendida para o caso de ocupação variável do PU durante toda a duração do quadro (Tang et al., 2011). O projeto de detector de energia com a abordagem TLC também foi estudado para projeto de códigos em regime de blocos de comprimento finito (Ozcan e Gursoy, 2013). O compromisso entre sensoriamento e eficiência energética da rede de CR foi analisado por meio da introdução de dois modelos: troca de canal e parada-e-espera (Zhang et al., 2014).

O estudo do desempenho do detector de energia também é investigado em trabalhos mais recentes. A análise do detector de energia utilizando a cooperação entre SUs têm sido abordada para aprimorar o desempenho de toda a rede (Tavana et al., 2016) (Zhang et al., 2017) (Godugu et al., 2020). Outros trabalhos recentes utilizando o detector de energia têm se voltado para a análise de intervalo adaptativo para o sensoriamento (Wang et al., 2017) (Alkady et al., 2019) e pôr fim a análise de dois limiares dinâmicos (Wan et al., 2019) para otimização de detecção de sinais.

1.1.2 Predição

Diferentes áreas têm utilizado esquemas de predição para descobrir padrões de hábitos e rotinas como por exemplo: predição de clima e predição de finanças (Sapankevych e Sankar, 2009). Na área de CR a predição pode ser utilizada de forma complementar ao sensoriamento de espectro. O sensoriamento trabalha de forma passiva enquanto a predição possui um caráter proativo. O SU pode realizar o processamento dos dados históricos de ocupação obtidos por meio de sensoriamentos anteriores e prever a ocupação futura do canal (Ding et al., 2017). Esse procedimento é conhecido como predição de espectro ou inferência espectral. O SU utiliza a inferência para realizar futuros sensoriamentos de espectro de forma seletiva.

No contexto de rádio cognitivo, diferentes algoritmos de predição têm sido utilizados, conforme apontado em estudos de revisão bibliográfica (Xing et al., 2013) (Ding et al., 2017). De acordo com esses trabalhos, as principais técnicas utilizadas para a predição no contexto de rádio cognitivo podem ser classificadas quanto à sua forma de predição em três grandes áreas (Ding et al., 2017): (i) modelos de predição linear clássicos, (ii) métodos baseados em modelos de Markov e (iii) métodos baseados em aprendizagem de máquina.

Os modelos de predição linear clássicos (i), são baseados em modelos matemáticos para predição de séries temporais. Nesse contexto as seguintes técnicas possuem destaque: modelo auto regressivo (Wen et al., 2008) (Eltholth, 2015), modelo de média móvel (Lin et al., 2009) (Matias et al., 2011), modelo auto regressivo de médias móveis (Ozden, 2013) e modelo auto regressivo integrado de médias móveis (Stoloiescu-Crisan, 2012) (Wang e Salous, 2011).

As técnicas baseadas em modelos de cadeia de Markov (ii) podem ser encontradas em diferentes trabalhos com destaque para as seguintes técnicas: modelo oculto de Markov (Saad et al., 2016) (Eltom et al., 2016) e processos de decisão de Markov parcialmente observáveis (Hoang et al., 2009).

Os algoritmos de aprendizado de máquina (iii) constituem a terceira grande área que têm ganhado projeção no emprego da predição temporal em rádios cognitivos. Essa classe de algoritmos têm suas raízes na ciência da computação sendo definida como subconjunto da área de inteligência artificial (Sapankevych e Sankar, 2009). Dentre os diferentes algoritmos de aprendizagem de máquina destacam-se: redes neurais e suas variantes (Tumuluru et al., 2010) (Baldo e Zorzi, 2008) (Eltholth, 2016), k-vizinhos mais próximos (do inglês, k-Nearest Neighbors ou kNN) (Chen et al., 2011), algoritmos genéticos (El Morabit et al., 2015), árvores de classificação (Soltani e Mutka, 2015) e por fim, máquinas de vetor de suporte (SVM, do inglês *Support Vector Machines*) (Wang et al., 2014) (Hou et al., 2014).

A predição de espectro pode ser classificada quanto à sua aplicação em três âmbitos: frequencial, espacial e temporal (Ding et al., 2017). A predição no domínio da frequência explora a correlação de utilização em canais adjacentes. Já predição espacial investiga a ocupação em locais geográficos. E por fim, a predição no domínio do tempo realiza a inferência do estado do espectro de acordo com as informações históricas sobre a evolução da ocupação espectral. Este

trabalho se concentra na predição ou inferência temporal, ao assumir que a atividade dos PUs em cada canal não possui correlação. Vale enfatizar que a ocupação geográfica não é explorada neste trabalho.

O algoritmo SVM (Vapnik e Lerner, 1963), é utilizado em diferentes áreas da ciência, como predição de mercado, estimativa de carga de energia, entre outras (Sapankevych e Sankar, 2009). O algoritmo SVM possui vantagens interessantes no uso de predição em comparação com as redes neurais como a garantia para convergência para a solução ideal e eficiência em termos computacionais (Sapankevych e Sankar, 2009). Uma variação do algoritmo para regressão foi proposta, sendo denominada regressão por vetor de suporte (SVR, do inglês *Support Vector Regression*) (Drucker et al., 1997).

No contexto de CR os algoritmos SVM e SVR já vêm sendo utilizado como ferramenta de predição. O algoritmo SVR pode ser empregado para processar os dados de ocupação do espectro (Yu et al., 2008). Esse algoritmo também pode ser utilizado para a predição da função densidade de probabilidade de duração de ocupação para o contexto de CR (Ni e Shen, 2011). Já foi validada a utilização do algoritmo SVM para prever a evolução da ocupação do espectro considerando tanto o domínio do tempo quanto as características de distribuição geográfica (Wang et al., 2014). Ainda em relação ao algoritmo SVM, é possível realizar a predição de troca de canal (em inglês, *handoff*) e também a análise dos canais inativos com alta precisão (Guo et al., 2011). Além disso o SVM pode ser utilizado em tempo real para a predição de espectro e seleção de canal (Zhang et al., 2015).

A comparação entre quatro técnicas diferentes de aprendizagem de máquinas para inferir o padrão de atividade de tráfego do usuário primário, mostrou que a técnica de SVM superou as demais em termos de acurácia e precisão. (Agarwal et al., 2016). Nesse caso foi considerado apenas um canal do usuário primário e um cenário baseado em *slots*. Essa análise verificou o algoritmo SVM com duas variações de *kernel* (função de mapeamento): linear e gaussiano, mostrando que o *kernel* linear produz melhores resultados. No entanto, não foi evidenciado com maiores detalhes as quantidades de dados passados e de dados futuros realizados para a estimação.

O algoritmo SVM tem sido avaliado em pesquisas mais recentes, como a classificação de sensoriamento em um ambiente cooperativo de SUs (Gupta e Majumder, 2019) e a classificação de sinal de energia de forma cooperativa por meio de um algoritmo SVM com duas etapas (Ghazizadeh et al., 2019). Por fim, já é possível utilizar o SVM para a classificação de PU malicioso em uma rede CR (Cadena Muñoz et al., 2020).

1.2 MOTIVAÇÃO E JUSTIFICATIVA

Entre os diferentes algoritmos de predição a técnica SVM poderia ser empregada para inferência com múltiplos estados à frente, ou seja, a análise para vários *slots* ou quadros futuros sequenciais.

Conforme descrito anteriormente, diferentes trabalhos, dentre os analisados ao longo desta pesquisa, utilizam as métricas do detector de energia baseados nas aproximações TLC. A análise para poucas amostras do detector de energia não foi abordada na literatura investigada e, por isso, um estudo aprimorado pode ser realizado para aumentar a robustez do detector de energia.

A predição em conjunto com o sensoriamento permite que o SU execute a detecção de ocupação apenas em canais preditos como ociosos e promove ganhos em termos de *throughput* (Yang e Zhao, 2015) e economia de energia. Nesse caso o quadro do SU é dividido em três intervalos: predição, sensoriamento e transmissão ou espera.

Diferentes pesquisas sobre predição de espectro enfatizam a estimação apenas para o próximo estado, ou *slot*, constituindo uma predição de curto prazo (Xing et al., 2013). A análise conjunta entre predição e a detecção de energia (Yang e Zhao, 2015) também pode ser estendida para o caso da análise com múltiplos passos à frente, o que pode aumentar o *throughput* e a economia de energia pois o SU executaria menos intervalos de predição e o sensoriamento de espectro em menos canais. A predição de longo prazo também poderia ser utilizada para o uso inteligente do espectro, permitindo que o SU evite ao máximo a troca de canais, reduzindo a reconfiguração desnecessária do circuito de rádio que é custosa em termos de energia (Bayhan e Alagoz, 2012) (Chang et al., 2013).

A exploração da análise conjunta de sensoriamento e predição de múltiplos estados à frente com a finalidade de melhorar o desempenho da rede de rádio cognitivo em termos de *throughput*, energia e troca de canais não foi explorada na literatura, conforme a investigação realizada ao longo desta pesquisa, dessa maneira, é uma área relevante para estudo.

1.3 OBJETIVOS

O objetivo principal deste trabalho é desenvolver um método melhor para a utilização da predição de múltiplos estados à frente que proporcione ganhos em termos de *throughput*, energia e troca de canais. Os objetivos específicos, com o propósito de cumprir o objetivo principal, são:

- Introduzir um algoritmo que busca aumentar o *throughput* da rede baseado em um ciclo de utilização do SU que combina o sensoriamento e a predição com múltiplos passos à frente.
- Elaborar um modelo analítico para a predição com múltiplos estados à frente.
- Analisar os efeitos em termos de energia e de troca de canais em razão do esquema de predição com múltiplos passos à frente.
- Desenvolver aproximações para probabilidade de detecção e probabilidade de falso alarme para o detector de energia em cenários que demandam quantidade moderada de amostras.

- Apresentar diferentes expressões de limite constante com base nas aproximações para probabilidade de detecção e probabilidade de falso alarme.

1.4 CONTRIBUIÇÕES CIENTÍFICAS

A seguir são apresentados os trabalhos elaborados em virtude dos resultados obtidos nesta pesquisa de doutorado:

1. F. G. M. Elias, E. M. G. Fernández e V. A. Reguera, “Multi-Step-Ahead Spectrum Prediction for Cognitive Radio in Fading Scenarios,” Publicado em **Journal of Microwaves, Optoelectronics and Electromagnetic Applications (JMOe)**, Vol. 19, No. 4, December 2020;
2. F. G. M. Elias e E. M. G. Fernández, “Uma Análise Aproximada do Detector de Energia,” Publicado em **Simpósio Brasileiro de Telecomunicações (SBrT)**, em Novembro de 2020;
3. F. G. M. Elias e E. M. G. Fernández, “An Analysis of Energy Detector Based on Improved Approximations of the Chi-square Distributions,” Aceito para publicação em **EURASIP Journal on Wireless Communications and Networking**, em Janeiro de 2021;

1.5 ESTRUTURA DO DOCUMENTO

A sequência deste documento está organizada da seguinte maneira: O Capítulo 2 apresenta a fundamentação teórica das técnicas utilizadas para sensoriamento e predição. As técnicas para a realização dos objetivos propostos na área de sensoriamento são exploradas no Capítulo 3, no final deste, serão apresentados os resultados obtidos. Os esquemas propostos para a predição são explorados no Capítulo 4, sendo que também serão apresentados os respectivos resultados ao final do mesmo. Por fim, o Capítulo 5 apresenta considerações finais sobre o assunto aqui investigado além de apresentar sugestões de trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 DETECTOR DE ENERGIA

O detector de energia implementado no SU é detalhado na Figura 2.1, onde as amostras do sinal recebido passam por um dispositivo de elevação ao quadrado seguido por um integrador, a saída é comparada com um valor de limiar.




Figura 2.1: Estágios do detector de energia implementado no SU.

O resultado da saída do detector de energia pode ser apresentado como uma hipótese binária, a ocupação ou a vacância do espectro:

$$\begin{cases} \mathbf{H}_0 : y(t) = n(t) \\ \mathbf{H}_1 : y(t) = h \cdot x(t) + n(t), \end{cases} \quad (2.1)$$

onde $n(t)$ representa o ruído na entrada do detector, amostrado no tempo t , h é o ganho do canal, $x(t)$ é o sinal do PU e $y(t)$ é o sinal recebido no SU. Nessa pesquisa serão avaliados os canais AWGN, $h = 1$, e *Rayleigh*. Na hipótese \mathbf{H}_0 apenas o ruído está presente no receptor SU, enquanto na hipótese \mathbf{H}_1 o sinal do PU está presente na recepção do SU. Em aplicações práticas, o detector de energia coleta um total de N amostras para realizar o teste de hipótese. Também é assumido o desvanecimento lento ou quase estático, de modo que o ganho de canal h permanece constante ao longo de vários (entre dez e quinze) intervalos de tempo.

As amostras de ruído $n(t)$ são consideradas como ruído gaussiano aditivo branco (AWGN, do inglês: additive white Gaussian noise) com média zero e variância $2\sigma_n^2$ (Atapattu et al., 2014). A relação sinal ruído (SNR, do inglês *signal-to-noise ratio*) entre PU e SU, medida no receptor do SU, é dada por $\gamma = \frac{|h|^2 \sigma_x^2}{\sigma_n^2}$. A variância de $x(t)$ é definida como $2\sigma_x^2$. O sinal recebido $y(t)$ passa pelos dois primeiros estágios do detector de energia e esta saída é correspondente à estatística de teste, Λ . A probabilidade de detecção P_d e a probabilidade de falso alarme P_f são definidas de acordo com a estatística de teste como:

$$\begin{cases} P_d = P[\Lambda > \lambda_{th} | \mathbf{H}_1] \\ P_f = P[\Lambda > \lambda_{th} | \mathbf{H}_0], \end{cases} \quad (2.2)$$

onde λ_{th} é o valor de limiar de detecção. A estatística de teste Λ segue diferentes funções de densidade de probabilidade quando analisada sob as hipóteses \mathbf{H}_0 e \mathbf{H}_1 , sendo indicadas como $f_{\Lambda|\mathbf{H}_0}(\lambda)$ e $f_{\Lambda|\mathbf{H}_1}(\lambda)$, respectivamente. Assim, P_f é a probabilidade associada ao detector

de energia identificar a existência de sinal, que na verdade, não está presente na entrada do receptor. Além disso, P_d é a probabilidade associada ao detector de energia atribuir a presença de um sinal sendo que o mesmo realmente esteja presente. A probabilidade de detecção errada $P_{md} = 1 - P_d$ (Urkowitz, 1967) indica a probabilidade associada ao detector de energia não identificar a presença de um sinal, apesar do mesmo está presente na entrada do receptor.

Em relação à hipótese \mathbf{H}_0 , a estatística de teste, Λ , é o resultado de uma soma de $2N$ quadrados de variáveis aleatórias gaussianas independentes (Atapattu et al., 2014). A saída do detector de energia, portanto, segue uma distribuição qui-quadrado central (χ^2_ν), com ν graus de liberdade, cuja função densidade de probabilidade (probability density function ou PDF) é:

$$f_{\Lambda|\mathbf{H}_0}(\lambda) = \frac{\lambda^{\nu/2-1} e^{-\lambda/2}}{\Gamma(\nu/2) 2^{\nu/2}}, \quad (2.3)$$

onde $\Gamma(a) = \int_0^\infty b^{a-1} e^{-b} db$ é a função gama (Gradshteyn e Ryzhik, 2014). A probabilidade de falso alarme é definida por meio de (2.2), ou seja, é o complemento da função distribuição acumulada (cumulative distribution function ou CDF) da distribuição qui-quadrado central, dada por:

$$P_f = 1 - F_{\Lambda|\mathbf{H}_0}(\lambda), \quad (2.4)$$

onde $F_{\Lambda|\mathbf{H}_0}(\lambda)$ representa a CDF de uma variável aleatória com distribuição qui-quadrado central, definida como:

$$F_{\Lambda|\mathbf{H}_0}(\lambda) = \frac{\gamma_L(\nu/2, \lambda/2)}{\Gamma(\nu/2)}. \quad (2.5)$$

A função $\gamma_L(a, b) = \int_0^b c^{a-1} e^{-c} dc$ é a função gama incompleta inferior (Gradshteyn e Ryzhik, 2014). A distribuição qui-quadrado central tende para a distribuição normal quando $\nu \rightarrow \infty$. Nesse caso, a abordagem do Teorema do Limite Central (TLC) é utilizada para obter (Johnson et al., 1995a):

$$F_{\Lambda|\mathbf{H}_0}^{TLC}(\lambda) \simeq \Phi\left(\frac{\lambda - \nu}{\sqrt{2\nu}}\right), \quad (2.6)$$

onde,

$$\Phi(a) = \frac{1}{2} \left[1 + \operatorname{erf}\left(\frac{a}{\sqrt{2}}\right) \right], \quad (2.7)$$

indica a CDF da distribuição normal. Definindo $\lambda = \frac{\lambda_{th}}{\sigma_n^2}$ e $\nu = 2N$ (Atapattu et al., 2014), então (2.4) pode ser reescrito como:

$$P_f^{TLC} \simeq 1 - \Phi\left(\frac{\lambda_{th} - N2\sigma_n^2}{\sqrt{N2\sigma_n^2}}\right) \simeq Q\left(\frac{\lambda_{th} - N2\sigma_n^2}{\sqrt{N2\sigma_n^2}}\right). \quad (2.8)$$

A função $Q(a) = 1 - \Phi(a)$, é conhecida como a função gaussiana-Q e representa a cauda da distribuição normal padrão. O sobrescrito (TLC) em (2.6) e (2.8) identifica o uso da abordagem TLC. A equação (2.8) é amplamente utilizada no detector de energia, como pode ser encontrado em diversas referências. No entanto, a abordagem TLC não é muito precisa, a menos que N seja muito grande (Johnson et al., 1995a).

Para a hipótese \mathbf{H}_1 , Λ é uma soma de $2N$ quadrados de variáveis aleatórias com distribuição gaussiana e média diferente de zero que segue uma PDF qui-quadrado não central ($\chi_\nu'^2$), com ν graus de liberdade e parâmetro de não centralidade φ :

$$f_{\Lambda|\mathbf{H}_1}(\lambda) = \frac{1}{2} e^{-(\lambda+\varphi)/2} \left(\frac{\lambda}{\varphi} \right)^{\nu/4-1/2} I_{\nu/2-1}(\sqrt{\varphi\lambda}), \quad (2.9)$$

onde $I_a(b) = (b/2)^a \sum_{c=0}^{\infty} \frac{(b^2/4)^c}{c! \Gamma(a+c+1)}$ é a função Bessel do primeiro tipo (Gradshteyn e Ryzhik, 2014). A probabilidade de detecção é definida usando (2.2), ou seja, a CDF complementar da distribuição qui-quadrado não central que pode ser escrita como:

$$P_d = 1 - F_{\Lambda|\mathbf{H}_1}(\lambda), \quad (2.10)$$

onde,

$$F_{\Lambda|\mathbf{H}_1}(\lambda) = 1 - Q_{\nu/2}(\sqrt{\varphi}, \sqrt{\lambda}). \quad (2.11)$$

A expressão $Q_M(a, b)$ é a função Marcum-Q (Abramowitz e Stegun, 1970). Novamente, diferentes trabalhos aplicaram a aproximação TLC em (2.11) (Johnson et al., 1995b), resultando em:

$$F_{\Lambda|\mathbf{H}_1}^{TLC}(\lambda) \simeq \Phi \left(\frac{\lambda - \nu - \varphi}{\sqrt{2(\nu + 2\varphi)}} \right). \quad (2.12)$$

Definindo $\lambda = \frac{\lambda_{th}}{\sigma_n^2}$, $\nu = 2N$ e $\varphi = 2N\gamma$ (Atapattu et al., 2014), a probabilidade de detecção é reescrita como:

$$P_d^{TLC} \simeq Q \left(\frac{\lambda_{th} - N(2\sigma_n^2(1 + \gamma))}{\sqrt{N(1 + 2\gamma)2\sigma_n^2}} \right). \quad (2.13)$$

Semelhante à (2.8), a probabilidade de detecção em (2.13) é válida para valores muito grandes de N , caso contrário, os valores aproximados começam a divergir daqueles obtidos pelas equações originais.

Um procedimento para estabelecer um excelente desempenho de detecção é a especificação de parâmetros constantes no projeto prático do detector de energia. Os parâmetros do projeto são os valores constantes \hat{P}_f e \hat{P}_d ou \hat{P}_{md} , onde $\hat{P}_{md} = 1 - \hat{P}_d$, definido para uma determinada SNR de projeto, $\hat{\gamma}$. A definição dos parâmetros estabelecidos resulta em um valor de limiar constante $\hat{\lambda}_{th}$ (Kumar et al., 2019).

O limiar pode ser selecionado com referência a um valor de taxa de detecção constante (*Constant Detection Rate*, em inglês ou CDR) ou com referência a um valor de taxa de falso alarme constante (*Constant False Alarm Rate*, em inglês ou CFAR) com base na abordagem TLC (Liang et al., 2008) (Kumar et al., 2019). O limiar CFAR é expressado de acordo com (Liang et al., 2008) (Atapattu et al., 2014):

$$\hat{\lambda}_{th}^{CFAR-TLC} = \left(Q^{-1}(\hat{P}_f) + \sqrt{N} \right) \sqrt{N} 2\sigma_n^2. \quad (2.14)$$

A expressão do valor de limiar CDR é indicada por (Liang et al., 2008) (Atapattu et al., 2014):

$$\hat{\lambda}_{th}^{CDR-TLC} = 2\sigma_n^2 \left[Q^{-1}(1 - \hat{P}_{md}) \sqrt{N(1 + 2\gamma)} + N(1 + \gamma) \right]. \quad (2.15)$$

A quantidade mínima de amostras N^* para valores específicos dos parâmetros \hat{P}_f , \hat{P}_d e $\hat{\gamma}$ pode ser definida combinando as expressões TLC (2.14) e (2.15) (Liang et al., 2008) (Atapattu et al., 2014):

$$N^* = \lceil \left(Q^{-1}(\hat{P}_f) - Q^{-1}(\hat{P}_d) \sqrt{2\hat{\gamma} + 1} \right)^2 \hat{\gamma}^{-2} \rceil \quad (2.16)$$

Supondo o cenário introduzido no Capítulo 1, onde o SU realiza o sensoriamento de forma periódica, N^* amostras são tomadas no intervalo de tempo de sensoriamento τ_S (Liang et al., 2008), assim $N^* = \tau_S f_S$, onde f_S é a frequência de amostragem. A Figura 2.2 apresenta o quadro de operação simples do SU, definido aqui como SU-S, que é constituído de duas etapas, τ_S e $T - \tau_S$: transmissão ou espera.




Figura 2.2: Quadro simples (Liang et al., 2008) de operação do SU (SU-S) com duração T , dividido em duas etapas: (i) τ_S sensoriamento e (ii) $T - \tau_S$ transmissão ou espera.

O algoritmo executado pelo SU que irá transmitir (fonte) ao implementar o quadro SU-S é apresentado por meio de um fluxograma na Figura 2.3(a). Supondo que apenas um canal seja monitorado, o SU executa a etapa de sensoriamento. Se o canal monitorado estiver ocupado o dispositivo cognitivo entra em modo espera e não transmite, caso contrário é possível realizar a transmissão.

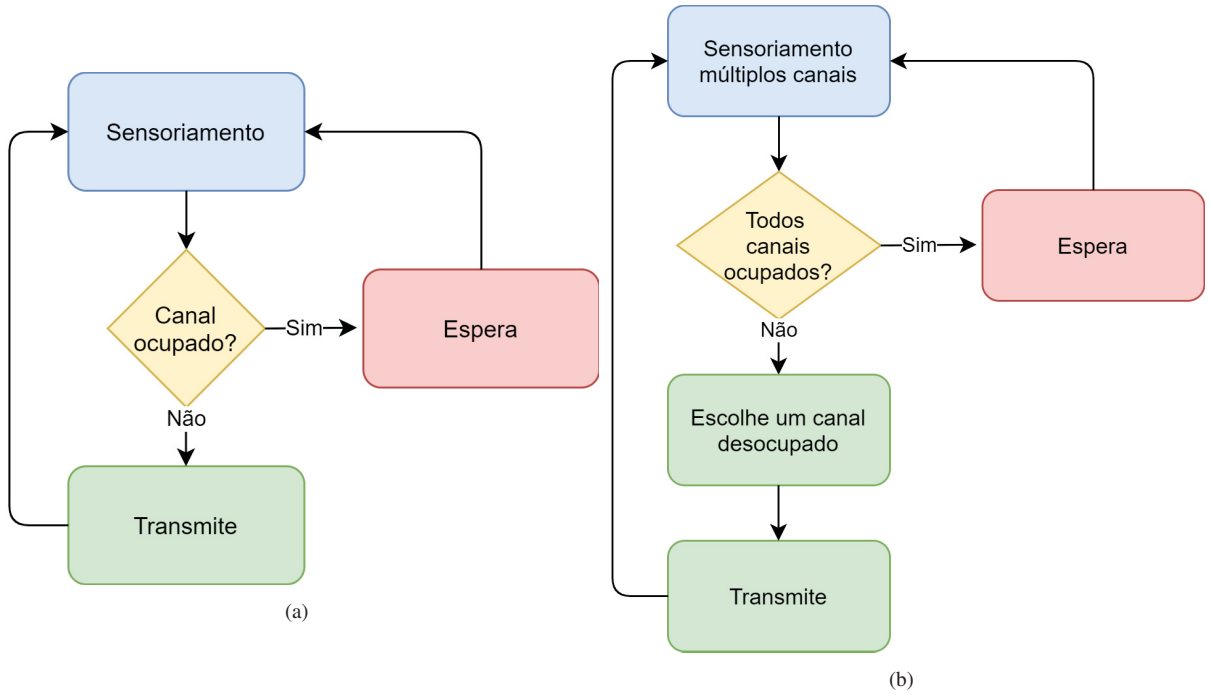


Figura 2.3: Algoritmo executado pelo SU para sensoriamento simples. (a) Caso para apenas um canal. (b) Caso para múltiplos canais.

O contexto anterior pode ser estendido para caso a rede CR seja composta por N_C canais. Dessa forma o algoritmo é modificado e apresentado por meio da Figura 2.3(b) para sensoriar vários canais, se todos estiverem ocupados o dispositivo SU entra em modo espera. Caso existam canais sensoriados desocupados o dispositivo SU escolhe de forma aleatória um desses para realizar a transmissão. Nessa situação o SU deve executar um esquema de sensoriamento multibanda (Hattab e Ibnkahla, 2014), os N_C canais existentes na rede CR são sensoriados na primeira etapa do quadro SU-S. Uma das formas de sensoriamento multibanda pode ser realizada de maneira paralela (Hattab e Ibnkahla, 2014), assim os N_C canais são sensoriados no intervalo τ_S .

A análise teórica do *throughput* da rede CR, supondo um canal AWGN, é realizada por meio de três situações possíveis: caso o SU esteja em modo de espera, o *throughput* da rede é nulo e indicado como $C_{0|AWGN}^{SU-S} = 0$. Quando a rede CR opera na ausência de usuários primários o *throughput* é máximo e indicado como $C_{1|AWGN}^{SU-S}$. Se a rede CR está livre de usuários primários pode-se definir a SNR deste enlace como $\gamma_S = \frac{|h'|^2 \sigma_s^2}{\sigma_n^2}$ onde σ_s^2 é a potência média do sinal gerado pelo SU, h' é o ganho do enlace entre SU e SU, assim,

$$C_{1|AWGN}^{SU-S} = \frac{T - \tau_S}{T} \log_2(1 + \gamma_S) = \alpha^{SU-S} C_{1|AWGN}. \quad (2.17)$$

O *throughput* do intervalo completo, T , do canal nesse caso é indicado como $C_{1|AWGN} = \log_2(1 + \gamma_S)$ para fins de simplificação. O fator α^{SU-S} é definido como:

$$\alpha^{SU-S} = \frac{T - \tau_S}{T}. \quad (2.18)$$

Esse fator corresponde ao ajuste devido a transmissão ser interrompida pelo intervalo de sensoriamento. Caso a rede CR opere na presença de usuários primários o *throughput* é reduzido. Caso exista sinal proveniente de PU na rede, existe interferência do sinal do PU,

$$C_{2|AWGN}^{SU-S} = \alpha^{SU-S} \log_2 \left(1 + \frac{\gamma_S}{1 + \gamma} \right) = \alpha^{SU-S} C_{2|AWGN}, \quad (2.19)$$

O *throughput* total do canal nesse outro caso é indicado como $C_{2|AWGN} = \log_2 \left(1 + \frac{\gamma_S}{1 + \gamma} \right)$ e o fator α^{SU-S} corrige o *throughput* adicionando o período gasto no sensoriamento. As distribuições de probabilidade do sensoriamento e o estado verdadeiro do canal são apresentadas na Tabela 2.1, acompanhadas dos efeitos causados pelo sensoriamento correto ou incorreto.

Tabela 2.1: As distribuições de probabilidades do estado verdadeiro do canal e sensoriamento

Estado verdadeiro do canal	Sensoriamento	Probabilidade	Efeito
desocupado	desocupado	$1 - P_f$	SU pode ocupar o canal
desocupado	ocupado	P_f	Subutilização do canal
ocupado	desocupado	$P_{md} = 1 - P_d$	SU transmite e interfere o sinal do PU
ocupado	ocupado	P_d	Sem ação sobre o canal

2.2 PREDIÇÃO

Conforme colocado no Capítulo 1, a predição pode ser realizada por meio de diferentes métodos. Os algoritmos de aprendizagem de máquina têm se destacado nos últimos anos devido à praticidade de implementação em hardware e software (Wong et al., 2020), associado aos excelentes resultados em termos de desempenho de predição. A literatura é extensa sobre o tema, que o categoriza sob diferentes aspectos ou atributos.

Algoritmos de aprendizagem de máquina são baseados em subáreas da matemática como álgebra linear e estatística para estabelecer modelos de relação entre os dados de entrada e saída. Essa relação entre dados de entrada e saída pode ser entendida como um modelo de aprendizagem computacional e é adquirida pelo dispositivo cognitivo por meio de uma etapa de treinamento.

De acordo com o método de processo de aprendizagem pode-se categorizar os algoritmos de aprendizagem de máquina em: (i) supervisionados, (ii) não supervisionados e (iii) aprendizagem por reforço (Bkassiny et al., 2012). Na aprendizagem supervisionada (i) o conjunto de dados de treinamento é apresentado ao dispositivo cognitivo com um conjunto de dados de entrada e um conjunto desejado de dados de saída. Na abordagem não-supervisionada (ii) o algoritmo é treinado apenas com um conjunto de dados de entrada. Por fim, nos algoritmos

baseados em aprendizagem por reforço (iii) figuram outras entidades de software que agem como elementos reguladores da aprendizagem.

Em relação ao atributo de formato de dados utilizados nas funções de treinamento é possível dividir o mesmo em três categorias: (a) classificação, (b) regressão e (c) estimação probabilística. Na classificação (a) os dados utilizados como entrada e saída das funções são discretos ou divididos em categorias. Na regressão (b) os dados trabalhados são representados por valores contínuos. Por fim na estimação probabilística (c) os dados de saída são valores probabilísticos.

Os algoritmos supervisionados possuem duas fases para sua execução conforme pode ser visualizado na Figura 2.4. Na primeira fase é realizado o treinamento do modelo que será empregado para a futura predição. Nesse caso, o algoritmo é alimentado com dados de entrada e também com dados de saída que são previamente escolhidos. O algoritmo na fase de treinamento é executado de forma a associar os dados de entrada com os dados de saída escolhidos, buscando a menor quantidade de erro. A saída desta etapa é um modelo baseado na associação.

A segunda fase é a predição efetiva que é realizada pelo dispositivo em operação. Na Figura 2.4, que apresenta um diagrama de etapas do algoritmo de aprendizagem de máquina, é possível observar que o modelo gerado na fase de treinamento é utilizado na fase de predição, esse recebe os dados de entrada e gera, por fim, a inferência. Os dados preditos podem divergir dos dados reais, nesse caso chamada de predição imperfeita. Neste trabalho, a previsão imperfeita foi considerada porque a técnica empregada pode realizar predições erradas.

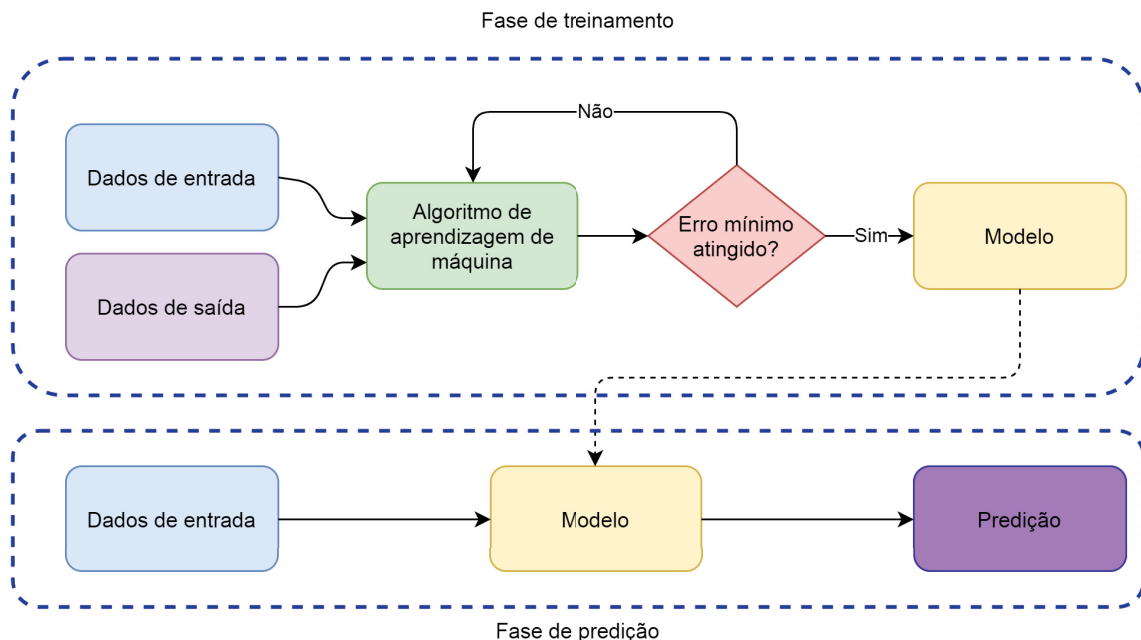


Figura 2.4: Etapas do Algoritmo de Aprendizagem de Máquina.

No contexto de CR a predição pode ser empregada em diferentes abordagens para solução de múltiplos problemas, sendo que uma das formas é o emprego de predição para ocupação espectral oportunista (Xing et al., 2013). Nesse caso, um esquema de predição é

implementado no dispositivo cognitivo, SU. Os resultados da etapa de sensoriamento, podem ser utilizados para alimentar o algoritmo de aprendizagem de máquina.

Mediante a análise do detector de energia, a potência recebida foi comparada com um limiar predefinido λ_{th} para definir o estado do canal. Um canal é considerado ocupado se a energia recebida se encontrar acima do valor de limiar predefinido e, caso contrário, considerado em estado inativo. Também é suposto um modelo de transmissão baseado em quadros (intervalos iguais e sequenciais com duração T conforme a Figura 2.2).

Com base nessas considerações, o histórico da ocupação do PU pode ser modelado por meio de uma série temporal binária (Cheema e Salous, 2019) (Yarkan e Arslan, 2007). Neste modelo o quadro atual (sendo analisado) é indicado por s^i , onde $s^i \in \{0, 1\}$. Um quadro ocupado é indicado como 1, e um quadro ocioso é indicado como 0. Portanto s é uma variável que indica se o i -ésimo quadro está ocupado ou ocioso. Os dados passados que alimentam o algoritmo preditor definem a janela de dados passados e os dados estimados estão dentro de uma janela de dados futuros. A quantidade de quadros ou *slots* na fase de treinamento é indicada com Tr e a quantidade de *slots* na fase de predição ou validação é indicada como Sl .

A Figura 2.5 ilustra a divisão em quadros de intervalos iguais para um determinado canal $\eta \in N_C$. A janela de observação (janela de dados passados) possui comprimento finito L e é definido como $s_\eta^L = \{s_\eta^{i-1}, s_\eta^{i-2}, s_\eta^{i-3}, \dots, s_\eta^{i-L}\}$. A janela de predição (janela de dados futuros) tem comprimento finito F e é definido como $\hat{s}_\eta^F = \{\hat{s}_\eta^{i+1}, \hat{s}_\eta^{i+2}, \hat{s}_\eta^{i+3}, \dots, \hat{s}_\eta^{i+F}\}$. Dados reais futuros são definidos como $s_\eta^F = \{s_\eta^{i+1}, s_\eta^{i+2}, s_\eta^{i+3}, \dots, s_\eta^{i+F}\}$. A predição para um estado à frente é o esquema de predição mais simples, onde $F = 1$. Nesse caso, $\hat{s}_\eta^F = \hat{s}_\eta^{i+1}$ e $s_\eta^F = s_\eta^{i+1}$. Na predição de múltiplos quadros ou estados futuros, portanto, $F > 1$.




Figura 2.5: Divisão em quadros para um determinado canal, são indicados: o quadro atual, a janela de observação e a janela de predição.

O vetor predito \hat{s}_η^F também pode ser analisado em termos do número de quadros ociosos futuros. Esse formato de notação é importante para o algoritmo de agendamento de canais, que será descrito com mais detalhes no Capítulo 4. O número de quadros ociosos futuros é contado a partir do quadro atual e leva em consideração apenas os quadros ociosos sequenciais. O SU pode usar essas informações para escolher um canal que foi predito como ocioso por uma quantidade maior de tempo. O número de quadros ociosos sequenciais subsequentes é indicado como \hat{u} , onde $\hat{u} \leq F$ e $\hat{s}_\eta^{\hat{u}} = \{\hat{s}_\eta^{i+1}, \hat{s}_\eta^{i+2}, \hat{s}_\eta^{i+3}, \dots, \hat{s}_\eta^{i+\hat{u}}\}$. Por exemplo, se uma janela futura com vários quadros à frente com $F = 5$ for igual a $\hat{s}_\eta^F = \{0, 0, 0, 1, 0\}$, o vetor que considera apenas os próximos quadros sequenciais inativos é dado por $\hat{s}_\eta^{\hat{u}} = \{0, 0, 0\}$. Esse valor também pode ser

representado no formato decimal e indicado como \hat{u} ; portanto, nesse exemplo, $\hat{u} = 3$, ou seja, há apenas três quadros ociosos futuros sequenciais.

Neste trabalho, como é suposta a predição imperfeita, ou seja, o valor predito para o slot n , \hat{s}^{i+n} , pode divergir de seu valor real, s^{i+n} . A probabilidade de predição incorreta é indicada como P_p^e . Nesta pesquisa foi suposto que o período de desvanecimento se mantém estático por uma quantidade igual à 10 quadros subsequentes.

2.2.1 Máquinas de Vetor de Suporte

As máquinas de vetor de suporte, ou SVM, possuem destaque entre os diversos algoritmos de aprendizagem de máquina: (i) possuem melhor desempenho para pequenos conjuntos de treinamento, em comparação com redes neurais artificiais (Bkassiny et al., 2012); (ii) pequeno número de parâmetros livres; (iii) computacionalmente eficiente (Ding et al., 2017); (iv) garantias de convergência para a solução ótima (Sapankevych e Sankar, 2009). A formulação utiliza o princípio de Minimização de Risco Estrutural, que apresenta desempenho superior em relação ao princípio de Minimização de Risco Empírico empregado por redes neurais convencionais (Al-Anazi e Gates, 2010).

Como outras técnicas de ML, o SVM padrão realiza a classificação de dados, ele é considerado um classificador linear binário não probabilístico. Conforme indicado no Capítulo 1, sua teoria é baseada na versão para regressão, SVR. Por ser um algoritmo supervisionado, necessita de um estágio de treinamento com um conjunto de amostras retiradas dos dados de problemas de espaço total. O algoritmo executa um processo de categorização dos dados de entrada em apenas uma das duas classes. Uma maneira de examinar a operação do algoritmo é tratar cada dado de entrada como um ponto em um hiperplano. O algoritmo então encontra uma linha com a distância máxima entre dois tipos de categorias de dados. Depois de executar o algoritmo, a saída é associada a apenas uma dessas categorias. Neste trabalho no entanto, será utilizada a versão do algoritmo para múltiplas classes (Allwein et al., 2000).

O objetivo do algoritmo é maximizar as diferenças entre as duas categorias para obter a classificação apropriada. Embora a fase de treinamento dessa técnica seja computacionalmente custosa, no momento da operação com o conjunto de dados real, ela possui a vantagem de ser muito eficiente. Dado um conjunto de dados $x(t)$, onde t é uma série de amostras discretas, $t = \{0, 1, 2, \dots, N-1\}$, $y(t+\delta)$ é um valor estimado no futuro. A análise de regressão visa definir uma expressão indicada como:

$$f(x) = w \cdot \phi(x) + \varepsilon, \quad (2.20)$$

onde w é o peso da função de predição e ε é o valor limite. A função $\phi(x)$ é conhecida como a função *kernel* e é usada quando o espaço de dados de entrada não é linear. A função *kernel* serve como um esquema para mapear os dados $x(t)$ para uma dimensão superior e, em seguida, realizar a regressão linear nesse espaço de dimensão superior. Um exemplo deste tipo de mapeamento está

exemplificado na Figura 2.6. Existem diferentes funções de *kernel* que atendem o mapeamento em dimensões superiores de forma adequada, como por exemplo: tangente hiperbólica, gaussiana e polinomial.




Figura 2.6: Esquema simplista de mapeamento em dimensão superior da função *kernel*.

Na fase de treinamento, o objetivo é encontrar os pesos e os valores limites ideais. Um dos critérios de escolha das variáveis é encontrar valores de w com níveis muito próximos entre si, esse critério é verificado pela norma euclidiana e o objetivo é minimizar $|w|^2$. Outro critério realizado na fase de treinamento é reduzir ao máximo o erro gerado no processo de estimativa de valor, R_{emp} , indicado como:

$$R_{emp}(f) = \frac{1}{N} \sum_{i=0}^{N-1} L(x(i), y(i), f(x(i), w)), \quad (2.21)$$

onde $L(\cdot)$ é uma função de custo, que depende da entrada $x(t)$, predição $y(t)$ e da função de regressão. Nessa fase, o algoritmo se enquadra em um problema de otimização computacional. Multiplicadores de Lagrange são usados para resolver mais especificamente esse problema de otimização convexa. O uso do *kernel* é o ponto principal no esquema SVM. Isso fornece a capacidade de mapear dados não lineares em espaços algébricos mais simples, onde o processo de otimização pode ser executado como o caso linear.

Neste trabalho, é utilizado o *kernel* linear em detrimento do *kernel* gaussiano, testes realizados nessa pesquisa mostraram um desempenho superior ao utilizar o *kernel* linear para ambos os cenários especificados nos Capítulos 3 e 4. Ao utilizar o *kernel* gaussiano os resultados apresentam em um aumento de P_p^e de cerca de 3%. Por fim, essa conclusão está em alinhamento com a literatura na área de CR (Agarwal et al., 2016).

3 APRIMORAMENTOS NO SENSORIAMENTO

Neste capítulo serão detalhados os esquemas propostos na etapa de sensoriamento com a finalidade de atingir parte dos objetivos desta pesquisa. Um modelo simples de sistema é introduzido e na sequência serão detalhados aprimoramentos na etapa de sensoriamento baseados em aproximações de distribuição de probabilidades qui-quadrado central e qui-quadrado não central. Por fim serão apresentados os resultados obtidos.

3.1 MODELO DO SISTEMA

Foram investigados dois cenários nesta pesquisa: o primeiro, mais simples, é abordado neste Capítulo para analisar as melhorias propostas para o sensoriamento. No primeiro cenário é assumido um par de transceptores PU e um par de transceptores SU. O receptor do PU está dentro do alcance do transmissor do SU. É suposto apenas um canal que é monitorado pelo SU de forma cíclica (quadro SU-S apresentado na Figura 2.2) para realizar a ocupação caso seja conveniente. Esse modelo é o mais simples e é utilizado apenas para a análise dos aprimoramentos propostos na fase de sensoriamento. A Figura 3.1 ilustra o cenário proposto. Nesta pesquisa não é avaliado o problema do transmissor oculto.




Figura 3.1: Cenário 1 elaborado para análise do sensoriamento. Apenas um canal, um par de transceptores PU e um par de transceptores SU.

3.2 APROXIMAÇÕES PARA OTIMIZAÇÃO NA ETAPA DE SENSORIAMENTO

A técnica do detector de energia é investigada primeiramente para casos com pequenas ou moderadas quantidades de amostras ($\gamma \approx 0$ dB) e em seguida para uma grande quantidade de amostras ($\gamma \ll 0$ dB). Para o detector de energia quanto menor o SNR, mais amostras são necessárias para realizar a distinção entre ruído e sinal.

3.2.1 Análise para alto SNR

A literatura clássica apresenta algumas aproximações para a FDA da expressão (2.5) como a aproximação de Fisher (Fisher, 1922):

$$F_{\Lambda|\mathbf{H}_0}^{Fi}(\lambda) \simeq \Phi(\sqrt{2\lambda} - \sqrt{2\nu - 1}). \quad (3.1)$$

Nesse caso, a probabilidade de falso alarme pode ser reescrita apenas substituindo as variáveis $\lambda = \frac{\lambda_{th}}{\sigma_n^2}$ and $\nu = 2N$ (Atapattu et al., 2014) em (3.1):

$$P_f^{Fi} \simeq Q\left(\frac{\sqrt{2\lambda_{th}}}{\sigma_n} - \sqrt{4N - 1}\right), \quad (3.2)$$

onde o índice Fi indica a aproximação de Fisher. Outra abordagem para a expressão (2.5) foi introduzida por Wilson e Hilferty (Wilson e Hilferty, 1931):

$$F_{\Lambda|\mathbf{H}_0}^{WH}(\lambda) \simeq \Phi\left(\sqrt{\frac{9\nu}{2}} \left\{\left(\frac{\lambda}{\nu}\right)^{1/3} - 1 + \frac{2}{9\nu}\right\}\right). \quad (3.3)$$

Substituindo novamente as variáveis λ e ν é possível obter:

$$P_f^{WH} \simeq Q\left(\frac{2 + 9N \left(\sqrt[3]{\frac{4\lambda_{th}}{N\sigma_n^2}} - 2\right)}{6\sqrt{N}}\right), \quad (3.4)$$

onde o índice WH indica a abordagem de Wilson e Hilferty para diferenciar a expressão de probabilidade de falso alarme. Aproximações para a FDA da distribuição qui-quadrado não central também são encontradas na literatura, como a abordagem de Abdel-Aty (Abdel-Aty, 1954):

$$F_{\Lambda|\mathbf{H}_1}^{AA}(\lambda) \simeq \Phi\left(\sqrt{\frac{9f}{2}} \left\{\left(\frac{\lambda}{\nu + \varphi}\right)^{1/3} - 1 + \frac{2}{9f}\right\}\right), \quad (3.5)$$

onde $f = \frac{(\nu+\varphi)^2}{\nu+2\varphi}$. Substituindo as variáveis $\lambda = \frac{\lambda_{th}}{\sigma_n^2}$, $\nu = 2N$ e $\varphi = 2N\gamma$ (Atapattu et al., 2014) em (3.5) a probabilidade de detecção pode ser reescrita como:

$$P_d^{AA} \simeq Q \left[\frac{(\gamma+1)\sqrt{N} \left(9 \left(\sqrt[3]{\frac{4\lambda_{th}}{N(\gamma+1)\sigma_n^2}} - 2 \right) + \frac{2\gamma+1}{(\gamma+1)^2 N^2} \right)}{6\sqrt{2\gamma+1}} \right], \quad (3.6)$$

onde o índice AA indica a abordagem de Abdel-Aty. Também é possível usar a abordagem Sankaran (Sankaran, 1963) para a FDA da distribuição qui-quadrado não central:

$$F_{\Lambda|\mathbf{H}_1}^S(\lambda) \simeq \Phi \left(\frac{\left(\frac{\lambda}{\nu+\varphi} \right)^d - (1 + dp(d-1-1/2(2-d)mp))}{d\sqrt{2p}(1+1/2mp)} \right), \quad (3.7)$$

onde $d = 1 - \frac{2}{3} \frac{(\nu+\varphi)(\nu+3\varphi)}{(\nu+2\varphi)^2}$, $p = \frac{\nu+2\varphi}{(\nu+\varphi)^2}$ e $m = (d-1)(1-3d)$. Nesse caso, a probabilidade de detecção pode ser reescrita substituindo as variáveis λ , ν e φ .

$$P_d^S \simeq Q \left[\frac{9(\gamma+1)(2\gamma+1)^5 N \left(\left(\frac{\lambda_{th}}{\sigma_n^2(2\gamma N+2N)} \right)^{\frac{\xi}{3(2\gamma+1)^2}} + \frac{\xi(3\gamma+1)(\gamma^2(2\gamma(9\gamma+10)+5)+6(\gamma+1)^2(2\gamma+1)^3 N)}{54(\gamma+1)^3(2\gamma+1)^6 N^2} - 1 \right)}{\xi \sqrt{\frac{2\gamma+1}{(\gamma+1)^2 N}} (\gamma^2(3\gamma+1) + 3(\gamma+1)(2\gamma+1)^3 N)} \right], \quad (3.8)$$

onde $\xi = 6\gamma^2 + 4\gamma + 1$.

Conforme apresentado no Capítulo 2 é possível definir um limiar constante de projeto ao manipular as expressões de probabilidade de falso alarme e probabilidade de detecção deixando as expressões apresentadas em função de λ_{th} . Definindo um valor constante para a probabilidade de falso alarme em (3.2), é possível obter:

$$\hat{\lambda}_{th}^{CFAR-F} = \frac{\sigma_n^2 \left(Q^{-1}(\hat{P}_f) + \sqrt{4N-1} \right)^2}{2}. \quad (3.9)$$

De forma análoga, definindo um valor constante de probabilidade de falso alarme em (3.4), é possível obter a seguinte expressão:

$$\hat{\lambda}_{th}^{CFAR-WH} = \frac{N\sigma_n^2 \left(2 - \frac{2-6\sqrt{N}Q^{-1}(\hat{P}_f)}{9N} \right)}{4}. \quad (3.10)$$

Seguindo o mesmo raciocínio, (3.6) pode ser arranjada em relação à probabilidade de detecção constante:

$$\hat{\lambda}_{th}^{CDR-AA} = \frac{N\sigma_n^2(\hat{\gamma}+1) \left(2 - \frac{\frac{2\hat{\gamma}+1}{N^2(\hat{\gamma}+1)^2} - \frac{Q^{-1}(1-\hat{P}_{md})6\sqrt{2\hat{\gamma}+1}}{\sqrt{N}(\hat{\gamma}+1)}}{9} \right)^3}{4}. \quad (3.11)$$

Também é possível definir o projeto de limiar fixo baseado em (3.8), com uma probabilidade de detecção fixa como:

$$\hat{\lambda}_{th}^{CDR-S} = \sigma_n^2(2\gamma N + 2N) \left[\frac{Q^{-1}(\hat{P}_d) (6\gamma^2 + 4\gamma + 1) \sqrt{\frac{2\gamma+1}{(\gamma+1)^2 N}} (\gamma^2(3\gamma + 1) + 3(\gamma + 1)(2\gamma + 1)^3 N)}{9(\gamma + 1)(2\gamma + 1)^5 N} - \left(\frac{(3\gamma + 1) (6\gamma^2 + 4\gamma + 1) (\gamma^2(2\gamma(9\gamma + 10) + 5) + 6(\gamma + 1)^2(2\gamma + 1)^3 N)}{54(\gamma + 1)^3(2\gamma + 1)^6 N^2} \right) + 1 \right] \left(\frac{3(2\gamma+1)^2}{6\gamma^2+4\gamma+1} \right). \quad (3.12)$$

As expressões (3.9) e (3.10) são representações alternativas para a abordagem CFAR-TLC (2.14). As expressões (3.11) e (3.12) são formas alternativas à abordagem CDR-TLC (2.15). As novas expressões apresentadas neste trabalho alcançam resultados mais precisos, como será discutido na Seção 3.3. Além do projeto de limite constante, as equações podem ser ajustadas para definir o número de amostras N para detecção conveniente.

Sabendo que $\nu = 2N$ e $\varphi = 2N\gamma$ e fazendo $f = 2N\beta$, onde $\beta = \frac{(1+\gamma)^2}{1+2\gamma}$ é possível reescrever (3.4) e (3.6) respectivamente como:

$$P_f^{WH} = Q \left(\sqrt{9N} \left\{ \left(\frac{\lambda}{2N} \right)^{1/3} - 1 + \frac{1}{9N} \right\} \right), \quad (3.13)$$

e

$$P_d^{AA} = Q \left(\sqrt{9N\beta} \left\{ \left(\frac{\lambda}{2N} \right)^{1/3} \left(\frac{1}{1+\gamma} \right)^{1/3} - 1 + \frac{1}{9N\beta} \right\} \right). \quad (3.14)$$

Deixando (3.15) em função do fator $\left(\frac{\lambda}{2N} \right)^{1/3}$ e definindo um valor de CFAR:

$$\left(\frac{\lambda}{2N} \right)^{1/3} = \frac{Q^{-1}(\hat{P}_f)}{\sqrt{9N}} + 1 - \frac{1}{9N}. \quad (3.15)$$

De forma análoga pode-se rearranjar (3.16) e definir um valor de CDR:

$$\frac{Q^{-1}(\hat{P}_d)}{\sqrt{9N\beta}} + 1 - \frac{1}{9N\beta} = \left(\frac{\lambda}{2N} \right)^{1/3} \left(\frac{1}{1+\gamma} \right)^{1/3}. \quad (3.16)$$

Assim é possível chegar a uma expressão para encontrar a quantidade de amostras, nesse caso indicado como \hat{N} , com base em valores de constantes de projeto de acordo com,

$$\frac{\frac{Q^{-1}(\hat{P}_d)}{3\sqrt{\hat{N}\beta}} + 1 - \frac{1}{9\hat{N}\beta}}{\frac{Q^{-1}(\hat{P}_f)}{3\sqrt{\hat{N}}} + 1 - \frac{1}{9\hat{N}}} = \left(\frac{1}{1+\gamma} \right)^{1/3}. \quad (3.17)$$

A equação (3.17) é uma expressão análoga à expressão (2.16) que define a quantidade de amostras N^* , no entanto a expressão (3.17) gera valores mais precisos pois é baseada nas novas aproximações avaliadas. O valor \hat{N} pode ser determinado por iteração.

Outra análise importante resultante dos parâmetros do detector de energia é a probabilidade total de erro $P_e = P_f + P_{md}$, que indica a expectativa de imprecisão do detector de energia. Se a probabilidade total de erro for avaliada com base em λ_{th} , ela tem um mínimo global, o que indica que há apenas um valor de λ_{th} minimizando P_e , isto é, há um limiar ideal λ_{th}^* (Atapattu et al., 2011), de modo que $\lambda_{th}^* = \arg \min_{\lambda_{th}} (P_e)$, isto é,

$$\frac{\partial P_e}{\partial \lambda_{th}} = \frac{\partial P_{md}}{\partial \lambda_{th}} + \frac{\partial P_f}{\partial \lambda_{th}} = 0. \quad (3.18)$$

Para alcançar esse resultado, foi escolhida uma nova expressão de probabilidade de falso alarme (3.2) e uma nova expressão de probabilidade de detecção (3.6), pela facilidade de manipulação algébrica.

Para resolver (3.18), deve-se analisar cada parte da equação separadamente. Usando a relação de função de erro $Q(x) = \frac{1}{2} - \frac{1}{2} \operatorname{erf}\left(\frac{x}{\sqrt{2}}\right)$, a primeira parte da equação (3.18), é a derivada da equação (3.2), reescrita como:

$$P_f^F = \frac{1}{2} - \frac{1}{2} \operatorname{erf}\left(\frac{\frac{\sqrt{2}\lambda_{th}}{\sigma_n} - \sqrt{4N-1}}{\sqrt{2}}\right). \quad (3.19)$$

Para resolver a derivada, deve-se utilizar a identidade:

$$\frac{\partial}{\partial x} \left(a + b \cdot \operatorname{erf}\left(\frac{c\sqrt{x} - d}{k}\right) \right) = \frac{bc \cdot e^{-\left(\frac{(d+c\sqrt{x})^2}{k^2}\right)}}{k\sqrt{\pi}\sqrt{x}}, \quad (3.20)$$

a derivada parcial de P_f^{Fi} em relação a λ_{th} é indicada pela expressão:

$$\frac{\partial P_f^{Fi}}{\partial \lambda_{th}} = - \frac{e^{-\frac{1}{2}\left(\sqrt{2}\sqrt{\frac{\lambda_{th}}{\sigma_n^2}} - \sqrt{-1+4N}\right)} \sqrt{\frac{\lambda_{th}}{\sigma_n^2}}}{2\sqrt{\pi}\lambda_{th}}. \quad (3.21)$$

A equação (3.6) pode ser reescrita em termos de P_{md} e a função de erro como:

$$P_{md}^{AA} = \frac{1}{2} + \frac{1}{2} \operatorname{erf}\left[\frac{(\gamma+1)\sqrt{N}\left(9\left(\sqrt[3]{\frac{4\lambda_{th}}{N(\gamma+1)\sigma_n^2}} - 2\right) + \frac{2\gamma+1}{(\gamma+1)^2N^2}\right)}{6\sqrt{2\gamma+1}}\right]. \quad (3.22)$$

A derivada parcial de P_{md}^{AA} em relação a λ_{th} pode ser obtida usando a identidade:

$$\frac{\partial}{\partial x} \left(a + b \cdot \operatorname{erf}\left(\frac{c\sqrt[3]{x} - d}{k}\right) \right) = \frac{2bc \cdot e^{-\left(\frac{(d+c\sqrt[3]{x})^2}{k^2}\right)}}{3k\sqrt{\pi}\sqrt[3]{x^2}}, \quad (3.23)$$

Finalmente, a derivada parcial de P_{md}^{AA} em relação a λ_{th} é indicada pela equação original:

$$\frac{\partial P_{md}^{AA}}{\partial \lambda_{th}} = \frac{e^{-\frac{1}{2} \left(\frac{9(\gamma+1)^2 N \left(3 \sqrt{\frac{\lambda_{th}}{\sigma_n^2 (2\gamma N + 2N)}} + \frac{2\gamma+1}{9(\gamma+1)^2 N} - 1 \right)^2}{(2\gamma+1)} \right)} \sqrt{\frac{(\gamma+1)^2 N}{2\pi\gamma+\pi}}}{2\sqrt{2}(\gamma+1)N\sigma_n^2 \sqrt{\frac{\lambda_{th}}{\sigma_n^2 (2\gamma N + 2N)}}^2} \quad (3.24)$$

As expressões (3.24) e (3.21) devem ser inseridas em (3.18) para encontrar o ponto ótimo para P_e .

3.2.2 Análise para baixo SNR

Em cenários com SNR baixo, ou seja, valores baixos de γ , é mais difícil detectar um sinal de forma eficaz e o detector de energia necessita de mais amostras.

A equação (2.16), que apresenta a quantidade de amostras necessárias para detecção apropriada, indica que para o modelo de canal AWGN o número de amostras depende apenas dos valores de projeto \hat{P}_f , \hat{P}_d e $\hat{\gamma}$. No caso do canal AWGN, o número de amostras é indicado por N , enquanto no caso do canal *Rayleigh* é referido como N_{Ray} . A detecção de sinal deve ser confiável mesmo em um ambiente de baixa relação sinal-ruído e estar em conformidade com as restrições de projeto ou padrão. O padrão IEEE 802.22 WRAN (Group et al., 2011) define $\hat{P}_f = 0,1$ mesmo sob condições onde a relação sinal-ruído entre PU e SU é extremamente baixa, por exemplo, $\gamma = -20$ dB, a probabilidade de detecção também é definida como um parâmetro de desempenho do projeto e geralmente $\hat{P}_d = 0,9$. No caso de uma restrição SNR baixa, o sinal tem pouco impacto sobre a variância da estatística sob a hipótese \mathbf{H}_1 . Como $\gamma \ll 1$ dB, (2.13) pode ser simplificada cancelando o termo γ no denominador (Atapattu et al., 2014):

$$P_d^{TLC|SNR} = Q \left(\frac{\lambda - N(2\sigma_n^2)(1 + \gamma)}{\sqrt{N}(2\sigma_n^2)} \right). \quad (3.25)$$

Sabendo que $Q(x) = \frac{1}{2} - \frac{1}{2} \text{erf}\left(\frac{x}{\sqrt{2}}\right)$ e usando a aproximação $\text{erf}(x) = \frac{2}{1+e^{-2,5x}} - 1$, como uma simplificação dos resultados encontrados em (Abramowitz e Stegun, 1970), a função $Q(x)$ pode ser reescrita como

$$Q(x) = \frac{1}{2} - \frac{1}{2} \left(\frac{2}{1 + e^{-\frac{2,5x}{\sqrt{2}}}} - 1 \right). \quad (3.26)$$

Combinando (3.25) e (3.26) é possível chegar a uma nova expressão de forma fechada para P_d em regime de baixa SNR:

$$P_d^{TLC|SNR} \approx \frac{1}{2} + \frac{1}{2} \left(1 - \frac{2}{1 + \exp - \frac{5(\lambda - N(2\sigma_n^2)(1+\gamma))}{(4\sqrt{2}N\sigma_n^2)}} \right). \quad (3.27)$$

Essa equação é uma excelente aproximação para (3.25). A probabilidade de detecção instantânea P_d depende da SNR, do número de amostras e também pode ser afetada pelo estado do canal sem fio. Os efeitos de sombreamento e desvanecimento no canal, por exemplo, tornam necessário avaliar a probabilidade média de detecção \bar{P}_d que pode ser obtida calculando a média P_d sobre a distribuição da SNR do canal, $f^{SNR}(\gamma)$, que resulta:

$$\bar{P}_d = \int_0^\infty P_d(\gamma) f^{SNR}(\gamma) d\gamma. \quad (3.28)$$

Em um cenário de desvanecimento *Rayleigh*, a distribuição da SNR é $f_{\text{Ray}}^{SNR}(\gamma) = \frac{1}{\gamma} \exp\left(-\frac{\gamma}{\gamma}\right)$. Usando $f_{\text{Ray}}^{SNR}(\gamma)$ e (3.27) em (3.28) resulta em

$$\bar{P}_{d\text{Ray}} = {}_2F_1 \left[1, \frac{2\sqrt{2}}{5\gamma\sqrt{N}}, 1 + \frac{2\sqrt{2}}{5\gamma\sqrt{N}}, -e^{\frac{5Q^{-1}(P_f)}{2\sqrt{2}}} \right]. \quad (3.29)$$

Na expressão acima, ${}_2F_1$ é a função de Gauss hipergeométrica (Gradshteyn e Ryzhik, 2014), indicada como

$${}_2F_1(a, b; c; z) = 1 + \frac{ab}{c \cdot 1} z + \frac{a(a+1)b(b+1)}{c(c+1) \cdot 1 \cdot 2} z^2 + \frac{a(a+1)(a+2)b(b+1)(b+2)}{c(c+1)(c+2) \cdot 1 \cdot 2 \cdot 3} z^3 + \dots \quad (3.30)$$

Essa equação é uma alternativa mais simples de $\bar{P}_{d\text{Ray}}$ encontrada em (Atapattu et al., 2014) e permite encontrar o número específico de amostras N para um determinado valor de $\hat{P}_{d\text{Ray}}$ a ser determinado por iteração.

3.3 RESULTADOS

Primeiramente foi realizada a análise dos resultados baseados nos esquemas propostos no Capítulo 3.

A Figura 3.2 mostra diferentes medidas de P_d em função de P_f , ou $P_d = f(P_f)$, por meio de curvas características de operação do receptor (em inglês *receiver operating characteristic curve*, ROC) que permitem avaliar o desempenho do detector de energia baseado nas expressões teóricas e também nas expressões aproximadas das probabilidades apresentadas no Capítulo 3.2. Os seguintes parâmetros foram utilizados: $N = \{10, 20, 50, 90\}$, $2\sigma_n^2 = 1$ e $\gamma = -5$ dB. Para cada valor de N , a Figura 3.2 fornece quatro curvas ROC: $P_d = f(P_f)$ gerada com base nas equações originais (2.4) e (2.10), $P_d^{TLC} = f(P_f^{TLC})$ obtida por meio da abordagem TLC, utilizando as equações (2.8) e (2.13), $P_d^{AA} = f(P_f^F)$ obtido pela combinação das expressões (3.2) e (3.6) e, por fim, $P_d^S = f(P_f^{WH})$ também gerada pela combinação das expressões (3.4) e (3.8).

Como foram apresentadas duas expressões de P_d e duas de P_f na Seção 3.2, quatro novas curvas ROC podem ser geradas apenas com as abordagens alternativas, porém optou-se pela apresentação de apenas duas novas curvas ROC para uma análise gráfica mais concisa. Nesse sentido, os pares escolhidos foram $P_d^{AA} = f(P_f^F)$ e $P_d^S = f(P_f^{WH})$. Quanto mais próxima




Figura 3.2: Curvas ROC teóricas e aproximadas para $N = 10$, $N = 20$, $N = 50$ e $N = 90$, com $\sigma_n = \sqrt{1/2}$ e $\gamma = -5$ dB.

do canto superior esquerdo estiver a curva ROC, melhor será seu desempenho, pois resulta em P_d mais alto com P_f mais baixo. O aumento de N é uma forma de aprimorar o desempenho da curva ROC, graficamente é possível visualizar que todas as curvas tendem a coincidir quando o valor de N aumenta. Por meio da análise da Figura 3.2 é possível verificar que a curva obtida por meio da abordagem TLC, além de possuir uma distância significativa em relação às curvas originais (2.4) e (2.10), também apresenta um desempenho inferior em relação às curvas geradas por meio das aproximações propostas. É possível observar, portanto, que as abordagens alternativas à abordagem TLC são mais precisas quando comparadas às curvas originais.

A Figura 3.3 apresenta a probabilidade de falso alarme medida e a probabilidade de detecção medida como funções de $\hat{\gamma}$ obtidas por meio de simulações. O detector de energia emprega os esquemas de limiar fixo apresentados no Seção 3.2. Em todas as simulações, o número ótimo de amostras \hat{N} é calculado de acordo com (3.17) para cada valor de $\hat{\gamma}$. Para a análise do projeto de limiar fixo, foram escolhidas duas situações. Na primeira o PU não está presente e apenas o ruído é considerado na entrada do receptor SU, os esquemas de limiar fixo utilizados nesse caso são baseados na taxa de falso alarme constante (CFAR), indicado por meio das expressões (2.14), (3.9) e (3.10). Como a figura apenas analisa a ausência ou presença de




Figura 3.3: Probabilidade medida de falso alarme (para $\hat{\lambda}_{th}^{CFAR-TLC}$, $\hat{\lambda}_{th}^{CFAR-Fi}$ e $\hat{\lambda}_{th}^{CFAR-WH}$) e medição da probabilidade de detecção de erros (para $\hat{\lambda}_{th}^{CDR-TLC}$, $\hat{\lambda}_{th}^{CDR-AA}$ e $\hat{\lambda}_{th}^{CDR-S}$) como função de $\hat{\gamma}$, utilizando $\hat{P}_f = 0,1$, $\hat{P}_d = 0,9$ e $\sigma_n = \sqrt{1/2}$

signal, não foi utilizado nenhum dos conjuntos de dados apresentado no Capítulo 4, sendo apenas introduzido na entrada do SU ruído ou sinal adicionado de ruído.

Na segunda situação, o PU está presente, os esquemas de limiar fixo usados nesse caso são baseados na taxa de detecção constante (CDR), indicados por meio das expressões (2.15), (3.11) e (3.12). O objetivo de cada situação é medir P_f para o primeiro caso ou P_{md} para o segundo caso. No primeiro, o valor da relação sinal-ruído do projeto, $\hat{\gamma}$, é usado apenas como um parâmetro para o projeto do detector de energia, pois é necessário estimar o número de amostras. A Figura 3.3 mostra a probabilidade medida de falso alarme P_f ou probabilidade de detecção de falha P_{md} em função de vários valores de $\hat{\gamma}$. Foi realizado um total de $N_a = 20000$ rodadas de simulação e foi considerado $2\sigma_n^2 = 1$. Para os diferentes valores de $\hat{\gamma}$ analisados, os valores fixos de projeto $\hat{P}_f = 0,1$ e $\hat{P}_d = 0,9$ foram mantidos. É possível verificar que os resultados para baixos valores de $\hat{\gamma}$ ($N \gg 1$) são muito semelhantes nas seis simulações realizadas. Na região $-20 \text{ dB} < \hat{\gamma} < -8 \text{ dB}$, os valores de P_f medidos no SU são realmente próximos aos valores do projeto \hat{P}_f .

Ainda na Figura 3.3, para $\hat{\gamma} > -8$ dB é possível observar uma diferença entre os valores medidos de P_f e P_{md} para todas as abordagens empregadas. No entanto, há uma diferença maior entre os valores medidos de P_f utilizando a abordagem TLC em comparação com o valor do projeto \hat{P}_f e também com os valores medidos pelas outras abordagens. Uma diferença ainda maior pode ser observada entre os valores medidos P_{md} usando a abordagem TLC e o valor do projeto \hat{P}_{md} . O desempenho geral do detector de energia com os limites fixos apresentados em (3.9) e (3.10) mostra maior proximidade de \hat{P}_f em comparação com a abordagem TLC (2.14). Para $\hat{\gamma} = 0$ dB o projeto com $\lambda_{th}^{CFAR-TLC}$ mostra uma diferença de cerca de 6% em comparação com o projeto $\lambda_{th}^{CFAR-WH}$. É possível observar que a figura apresenta um comportamento intermitente (sobe-e-desce) devido ao fator de arredondamento da expressão de cálculo de quantidade mínima de amostras conforme expressão (2.16).

O desempenho do detector de energia na situação onde o sinal está presente e medido por meio dos limites constantes apresentados em (3.11) e (3.12) também mostram maior proximidade de \hat{P}_{md} . Para $\hat{\gamma} = 0$ dB o projeto com $\hat{\lambda}_{th}^{CDR-TLC}$ mostra uma diferença de cerca de 16% em comparação com o projeto $\hat{\lambda}_{th}^{CDR-AA}$. Essas diferenças ocorrem porque para o mesmo número de amostras definidas no projeto, as probabilidades de falso alarme e de detecção apresentam valores diferentes conforme pode ser observado na Figura 3.2.

A Figura 3.4 apresenta a quantidade de amostras de projeto em função da SNR de projeto $\hat{\gamma}$. Foram utilizados três pares de valores de projeto \hat{P}_f e \hat{P}_d para a análise dos resultados. É possível realizar uma comparação entre dois valores de projeto N^* e \hat{N} , utilizando as expressões 2.16 e 3.17. É possível observar uma diferença entre as quantidades de amostras nas duas abordagens. Essa diferença é no máximo de apenas uma amostra e não impacta o desempenho do detector de energia para valores de SNR baixo. No entanto essa diferença é significativa para valores de SNR moderado onde $\gamma \approx 1$ dB, onde o detector de energia trabalha com uma pequena quantidade de amostras. Dessa forma a abordagem proposta define uma quantidade de amostras menor que a abordagem TLC. A Figura apresenta apenas uma janela de $\hat{\gamma} \approx 1$ dB em razão dessa região apresentar a maior diferença de valores. Para $\hat{\gamma} \ll 0$ dB os resultados das duas expressões se igualam.

A Figura 3.5 mostra o alto grau de similaridade entre as curvas de P_d em função de N em um cenário de baixo SNR ($\hat{\gamma} \ll 0$ dB). A Figura 3.5 foi gerada pelas equações em (Atapattu et al., 2014) e equações (3.27) e (3.29). Foram utilizados os valores de projeto $\hat{P}_d = 0,9$, $\hat{P}_f = 0,1$, e $\hat{\gamma} = -20$ dB em um canal AWGN com $2\sigma_n^2 = 1$. Em termos computacionais foram realizadas simulações sendo possível observar que a equação (3.29) é aproximadamente 4,5 vezes mais rápida que a equação apresentada em (Atapattu et al., 2014), pois possui menos operações. É possível observar a diferença entre quantidade de amostras para canal AWGN $N^* = 66.351$ e canal com desvanecimento Rayleigh $N^* = 66.718$. O número correto de amostras para um canal Rayleigh foi determinado a partir da Equação (3.29).

A Figura 3.6 mostra a probabilidade total de erro $P_e = P_f + P_{md}$ simulada, usando duas abordagens: equações originais e aproximações apresentadas na Seção 3.2 dependendo do limiar




Figura 3.4: Comparação entre valores de projeto para N .

de detecção, e do número de amostras. Para gerar o presente resultado, diferentes valores de projeto foram usados \hat{P}_f , \hat{P}_d , $\sigma_n = 1$ e $\text{SNR} = 0$ dB. Primeiro, é possível verificar o local mínimo de ambas as curvas que mostram os valores ótimos de λ_{th} e N , conforme discutido na Seção 3.2 para vários valores de projeto. Quanto menor a probabilidade total de erro, maiores serão os valores de λ_{th} e N , como esperado. Pode-se observar também que as aproximações propostas nesta pesquisa se ajustam adequadamente às curvas das equações originais (2.4) e (2.10). As diferenças em termos do número de amostras N e do nível de limiar de detecção ótimo foram menores que 1%, quando comparadas com as funções originais e com o modelo de probabilidade de erro total proposto, mostrando assim a precisão dos resultados obtidos.

A Figura 3.7 mostra a probabilidade de falso alarme medida e a probabilidade de detecção como funções de $\hat{\gamma}$. Nesse cenário foi verificado o projeto de limiar constante proposto para uma ampla faixa de SNR, porém o mesmo número de amostras $N = 50$ é mantido para cada valor SNR avaliado. Os parâmetros do projeto foram definidos como $\hat{P}_d = 0,9$ e $\hat{P}_f = 0,1$, que representa $\hat{\gamma} \approx -4$ dB, com o número limitado de amostras. As curvas geradas pela simulação foram obtidas primeiramente encontrando os valores limites constantes para cada uma das abordagens apresentadas. Para todas as abordagens CFAR, o valor P_f é constante e igual a \hat{P}_f , o mesmo ocorre para todas as abordagens CDR, o valor P_d também é constante e igual a \hat{P}_d .




Figura 3.5: Probabilidade de detecção teórica em função do número de amostras para um canal AWGN e um canal de desvanecimento de *Rayleigh* para a abordagem proposta e a literatura.

Além disso, para cada valor limiar de CDR, as probabilidades de falso alarme são calculadas, portanto, a expressão (2.8) é calculada em relação a (2.15), (3.2) é calculado usando (3.11) e (3.4) é calculado com (3.12). Para cada valor de limiar CFAR, as probabilidades de detecção são calculadas, portanto, a expressão (2.13) é calculada usando (2.14), (3.6) é calculada com (3.9) e (3.8) é calculado em relação a (3.10).

Pode-se observar na Figura 3.7 que avaliando vários valores SNR e mantendo o mesmo número de amostras, as novas expressões geram um valor alto para P_d medido e um valor baixo para P_f medido em relação aos limiares baseados na abordagem TLC. Para $\gamma = -10$ dB, $P_f^F(\hat{\lambda}_{th}^{CDR-AA}) = 0,72$, enquanto $P_f^{TLC}(\hat{\lambda}_{th}^{CDR-TLC}) = 0,76$, o que fornece um ganho de até 5%. Como pode ser observado na Figura 3.7, para uma SNR muito baixa a probabilidade de falso alarme é alta e a probabilidade de detecção é baixa devido ao número reduzido de amostras. Ao aumentar a SNR, as probabilidades tendem a melhorar até que os valores medidos se aproximem dos definidos no projeto $\hat{P}_d = 0,9$ e $\hat{P}_f = 0,1$, na região próxima a $\gamma \approx 4$ dB. Aumentando o SNR, a probabilidade de detecção medida atinge o valor máximo.

Os resultados da simulação apresentados na Figura 3.8 mostram o *throughput* da rede CR, descrita no Capítulo 2.1, em função de γ para um número constante de amostras. Foram

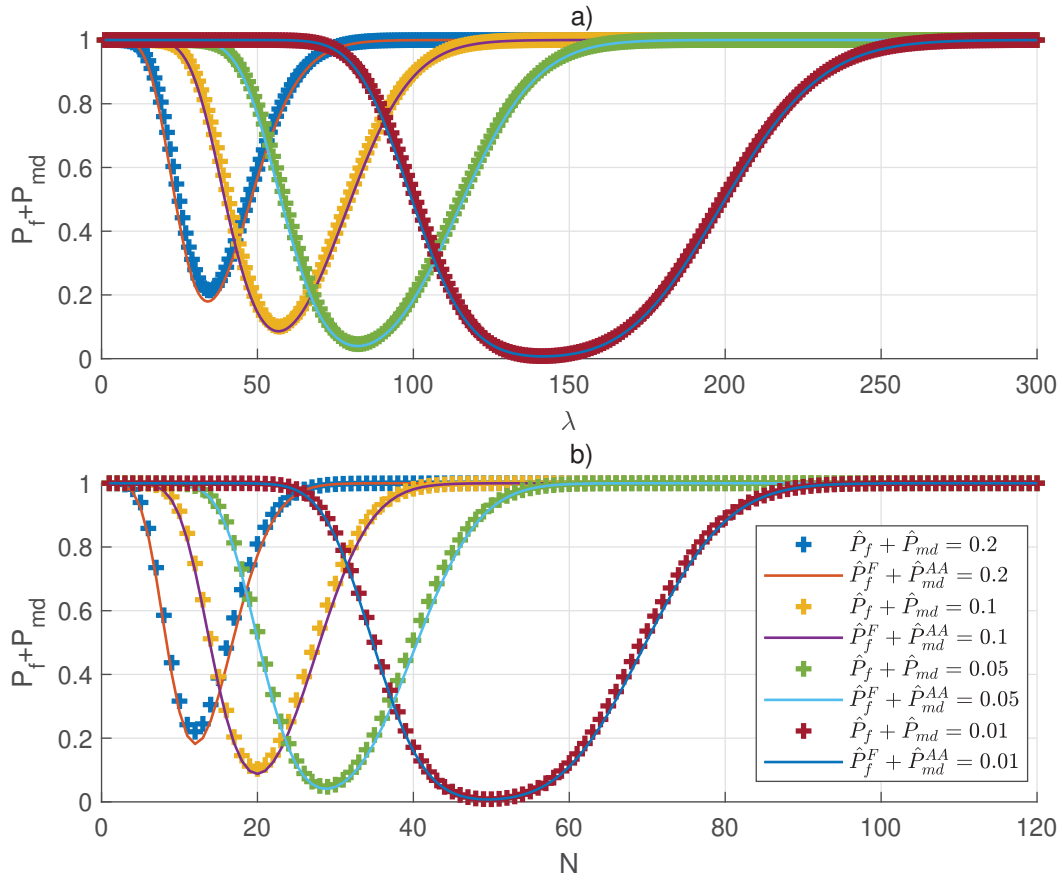


Figura 3.6: Probabilidade total de erro $P_f + P_{md}$ simulada, usando equações e aproximações originais, dependendo de (a) limiar de detecção e (b) número de amostras, usando valores de design diferentes \hat{P}_f , \hat{P}_d , $\sigma_n = 1$ e $\text{SNR} = 0\text{dB}$

Tabela 3.1: Tabela de comparação dos resultados da simulação de *throughput* (bit/uso do canal).

SNR (dB)	$\hat{\lambda}_{th}^{CFAR-TLC}$	$\hat{\lambda}_{th}^{CFAR-TLC}$	$\hat{\lambda}_{th}^{CFAR-TLC}$	$\hat{\lambda}_{th}^{CDR-TLC}$	$\hat{\lambda}_{th}^{CDR-AA}$	$\hat{\lambda}_{th}^{CDR-S}$
-15	5.7671	5.7584	5.7744	0.8360	0.9226	0.8639
-9	5.4798	5.4853	5.5095	1.6500	1.8551	1.7816
-7	5.2436	5.2518	5.2770	2.5044	2.7597	2.6821
-4	4.8262	4.8145	4.8271	4.6065	4.6993	4.6425
0	4.6745	4.6741	4.6741	5.3040	5.3040	5.3039
3	4.6741	4.6741	4.6741	5.2929	5.2929	5.2929

utilizados os mesmos parâmetros de (Kumar et al., 2019), onde $T = 100$ ms, $\tau_S = 2,5$ ms, $\gamma_S = 20$ dB, $\hat{P}_f = 0,1$, $\hat{P}_d = 0,9$ e a atividade de PU é definida como $P(H_0) = 0,8$ e $P(H_1) = 0,2$. Para essa simulação, foi empregado uma quantidade constante de amostras $N = 50$ e foi analisada o novo projeto de limiar constante conforme descrito na Seção 3.2. É possível observar um ganho em termos de *throughput* quando o novo limiar constante é empregado em comparação com o limiar constante baseado na abordagem TLC. Para $\hat{\gamma} = -9$ dB, a taxa de transferência da rede SU é $R = 5,4853$ bit/uso do canal quando é empregado $\hat{\lambda}^{CFAR-F}$, a taxa de transferência com




Figura 3.7: Probabilidades medidas em função de γ para um número constante de amostras $N = 50$. As setas mostram as probabilidades medidas na região das probabilidades de projeto.

$\hat{\lambda}^{CFAR-TLC}$ com base na abordagem TLC é $R = 5,4798 \text{ bit/uso do canal}$, o que representa um ganho de até 0,6%. O ganho de rendimento é maior quando a comparação é feita entre $\hat{\lambda}^S$ ou $\hat{\lambda}^{AA}$ e $\hat{\lambda}^{CDR}$. Para $\hat{\gamma} = -9 \text{ dB}$, um ganho de até 12% é observado quando o limiar constante $\hat{\lambda}^{CDR-S}$ é usado em comparação com $\hat{\lambda}^{CDR-TLC}$. Além disso, um ganho de até 7% é apresentado quando o limiar constante $\hat{\lambda}^{CDR-AA}$ é empregado em comparação com $\hat{\lambda}^{CDR-TLC}$, para $\hat{\gamma} = -7 \text{ dB}$. Esses resultados mostram que em uma situação desfavorável onde o SNR medido é diferente do SNR $\hat{\gamma}$ do projeto, há um ganho moderado em termos de *throughput* para a rede de rádio cognitiva quando são utilizadas as novas abordagens apresentadas nesta pesquisa. Alguns valores numéricos são comparados na Tabela 3.1.




Figura 3.8: *Throughput* para o enlace do SU em função de γ para um número constante de amostras $N = 50$.

4 APRIMORAMENTOS NA PREDIÇÃO

Neste capítulo serão detalhados os esquemas propostos na etapa de predição com a finalidade de atingir a segunda parte dos objetivos desta pesquisa. Primeiramente será apresentado o modelo de sistema empregado e na sequência serão apresentados os aprimoramentos na etapa de predição com múltiplos passos à frente. Por fim serão apresentados os resultados obtidos.

4.1 MODELO DO SISTEMA

O cenário utilizado na predição apresenta um sistema mais complexo que o cenário introduzido na Figura 3.1, sendo elaborado para análise da predição com múltiplos passos à frente. Nesse caso foram considerados múltiplos canais, assim, a rede CR é constituída por um par de transceptores SU, os quais coexistem com diversos equipamentos PU. A Figura 4.1 apresenta o conceito do Cenário 2. Nesse cenário cada par de transceptor PU estabelece um enlace que utiliza apenas um canal. Os equipamentos PU podem acessar uma quantidade de N_C canais licenciados, os quais podem ser acessados de forma oportunista pelo equipamento SU. Quando um canal está disponível, o SU pode acessá-lo para transmitir ao receptor cognitivo correspondente. No exemplo da Figura 4.1 um par de transceptores SU compartilha o "Canal B". O receptor SU está ciente do canal em uso pelo transmissor SU por meio de um Canal de Controle Comum (CCC) com largura de banda limitada. O PU não tem acesso ao CCC pois não necessariamente possui cognição como o SU. Os detalhes do CCC não serão investigados neste trabalho, pois aumentaria a complexidade dos esquemas analisados e fugiria do escopo desta pesquisa. A ocupação de qualquer canal devido à atividade de PU é considerada independente da ocupação em qualquer outro canal, ou seja, não existe correlação entre canais adjacentes. Nesse cenário é realizada a análise tanto para o caso AWGN como para o caso do canal com desvanecimento de *Rayleigh*.

4.1.1 Modelagem de Tráfego

Foram utilizadas duas modelagens de tráfego do PU durante a investigação aqui realizada. O primeiro modelo é o tráfego exponencial *on-off* (Adas, 1997) (Chandrasekaran, 2009) (Barnes et al., 2016), gerado de forma analítica por meio da distribuição exponencial. O segundo modelo é empírico e foi obtido por meio de medições reais (Wellens et al., 2009)(Wellens e Mähönen, 2010). Ambos os modelos são constituídos por sequências de quadros com durações de ocupação e ociosidade dos PUs.

No primeiro caso, a ocupação do canal pode ser modelada como um processo independente distribuído exponencialmente, onde os intervalos de tempo entre a ocupação e a




Figura 4.1: Cenário 2 elaborado para análise da predição com múltiplos passos a frente onde diversos transceptores PU ocupam diferentes canais.

desocupação de um PU seguem distribuições exponenciais, com média $\frac{1}{\mu_0}$ e $\frac{1}{\mu_1}$ respectivamente, sendo que t_{on} e t_{off} representam a duração dos períodos de ocupação e ociosidade respectivamente.

$$\begin{aligned} f_{\mu_0}(t_{off}) &= \mu_0 \cdot e^{-\mu_0 \cdot t_{off}}, \\ f_{\mu_1}(t_{on}) &= \mu_1 \cdot e^{-\mu_1 \cdot t_{on}}. \end{aligned} \quad (4.1)$$

Os parâmetros de média, μ_0 e μ_1 , são responsáveis por alterar a densidade do tráfego e podem ser obtidos como:

$$\begin{aligned} \mu_0 &= \tau \cdot (1 - \rho), \\ \mu_1 &= \tau \cdot \rho. \end{aligned} \quad (4.2)$$

O parâmetro τ é a taxa de alteração dos padrões de ocupação de PU, os parâmetros ρ e $(1 - \rho)$ regulam a densidade dos períodos de *on* e *off*. A Figura 4.2 apresenta dois conjuntos de dados, ambos com o mesmo valor de ρ mas com diferentes valores de τ . É possível observar que com o aumento no valor de τ as transições ocorrem com menos frequência.

A probabilidade associada à atividade de PU (densidade de tráfego) é indicada de duas maneiras: $P(H_0)$, onde nenhuma transmissão é realizada ou $P(H_1)$, caso o PU esteja utilizando o canal. Em consequência, a intensidade de tráfego da rede CR, ρ , é equivalente à probabilidade

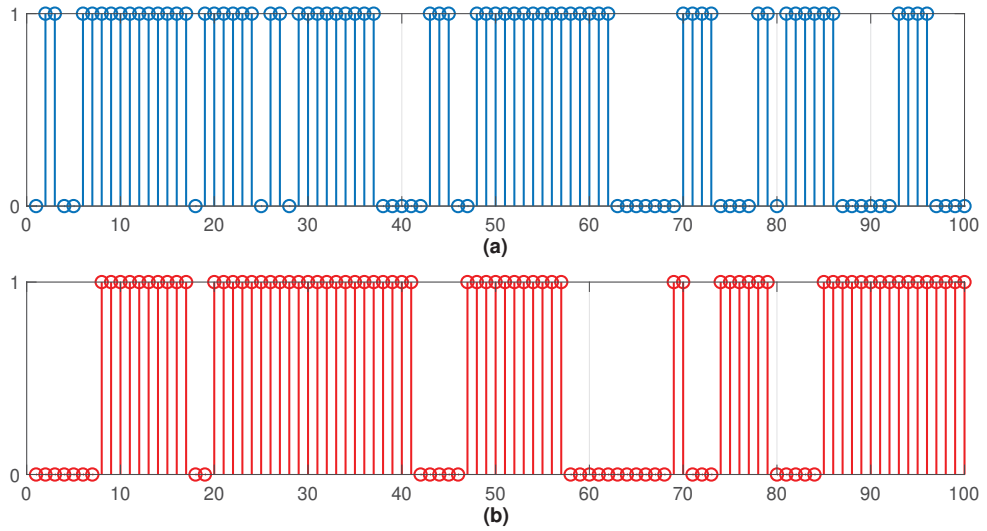


Figura 4.2: Tráfego com alta densidade $\rho = 0,7$, cerca de 70% dos quadros ocupados. (a) Transição entre estados mais frequente *on-off* com $\tau = 10$, e (b) taxa de transição menos frequente com $\tau = 30$.

de $P(H_1)$. Também é assumido que a atividade do PU permanece constante durante todo o período de detecção.

O conjunto de dados empíricos foi obtido por meio de várias medições realizadas em duas cidades: Aachen na Alemanha e Maastricht na Holanda (Wellens e Mähönen, 2010). Os resultados foram disponibilizados em um banco de dados na internet (Wellens e Mähönen, 2009). No total foram realizadas medições em uma extensa faixa de frequência variando de 20MHz a 6GHz, dividida em quatro etapas de varreduras. Foram utilizados os resultados da primeira etapa que cobriu a faixa $f_a = 20\text{MHz}$ -1520MHz com frequência central em $f_c = 770\text{MHz}$, essa grande faixa foi dividida em 8192 subbandas cada uma com largura de 200kHz e frequência central f'_c . Cada varredura levou aproximadamente 1,8 segundos, sendo que 1000 amostras correspondem a aproximadamente 30 minutos de amostragem. As medições foram realizadas por meio de um equipamento analisador de espectro Agilent E4440A e uma antena discone multibanda AOR DA-5000, as medições foram realizadas em ambiente externo, no telhado ou laje superior de prédios em áreas urbanas. Os resultados apresentados no banco de dados foram gerados na unidade dBm, com isso, para transformá-los em sinal de ocupação binária (ocupação ou ociosidade) foi necessário utilizar um valor limiar. Nesse caso foi utilizado um valor de limiar $\lambda_{th|SNR} = -107$ dBm, conforme sugestão dos autores do trabalho (Wellens e Mähönen, 2010).

A Figura 4.3 apresenta dois fragmentos dos valores empíricos de medição em duas bandas distintas (566,5MHz e 724,2MHz). Na figura são apresentados os valores discretos de ocupação e ociosidade, já selecionados por meio do valor de limiar escolhido.

O software MATLAB 2018 foi usado para gerar o ambiente de simulação. Esta pesquisa utiliza o modelo multiclasse para SVM apresentado no MATLAB *Native Statistics and Machine Learning Toolbox*. Conforme mencionado anteriormente, foi adotado o parâmetro *kernel* linear.

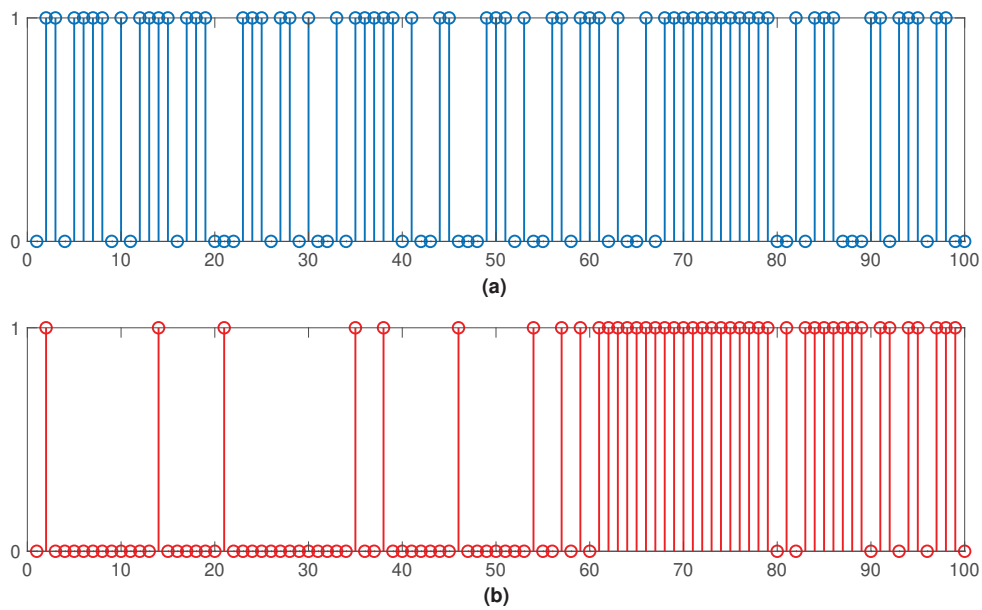


Figura 4.3: Tráfego real (a) 566,5 MHz e (b) 724,2 MHz.

A técnica SVM foi concebida inicialmente como um classificador para apenas duas classes, no entanto foi empregada a variação do SVM para predição de múltiplas classes (Allwein et al., 2000). Neste trabalho foram utilizados dados binários para definir a ocupação ou ociosidade do espectro, para realizar a predição com o algoritmo SVM, a janela de observação foi tratada como um conjunto de valores binários e foi realizada uma operação simples na janela de predição: os valores binários da janela futura foram ajustados para seu correspondente em valor decimal, sendo executada uma conversão binária decimal simples. Essa conversão simples ocorre antes da inserção dos dados no algoritmo do preditor. Esse esquema de conversão é utilizado pela primeira vez na fase de treinamento.

Por exemplo, considerando $F = 3$, o algoritmo preditor define oito diferentes classes possíveis, um resultado direto da combinação binária dos três *slots* preditos. Em sua fase de treinamento, o algoritmo faz a associação entre uma janela de observação (ocupação binária) com um número em formato decimal. Na fase de validação, quando o algoritmo preditor recebe uma janela de observação, o mesmo retorna um valor decimal como inferência. Após essa etapa é realizada a conversão inversa do valor decimal para seu correspondente binário. Conforme já mencionado, os dados de entrada (janela observada) não são convertidos, os mesmos são alimentados no preditor como dados binários.

4.2 QUADRO COM PREDIÇÃO E SENSORIAMENTO

4.2.1 Análise para um estado à frente

É possível alterar o quadro do SU apresentado na Figura 2.2 adicionando a etapa de predição. Primeiramente serão apresentados os cálculos desenvolvidos para $F = 1$ (Yang e Zhao, 2015), na sequência serão estendidos os cálculos para $F > 1$. A Figura 4.4 apresenta o quadro do SU, indicado nesta pesquisa como SU-P, com duração T composto por três etapas: τ_P (predição), τ_S (sensoriamento) e $T - \tau_P - \tau_S$ (transmissão ou espera).




Figura 4.4: Quadro de operação SU-P (Yang e Zhao, 2015), com duração T , dividido em três etapas: (i) τ_P predição, (ii) τ_S sensoriamento e (iii) $T - \tau_P - \tau_S$ transmissão ou espera.

O algoritmo executado pelo SU ao implementar os estágios de predição e sensoriamento (Yang e Zhao, 2015) é apresentado em forma de fluxograma na Figura 4.5. O esquema de predição realiza a inferência de apenas um estado à frente com base nos dados históricos coletados. O resultado da predição é analisado, se houverem canais preditos desocupados é realizado sensoriamento nesses canais. Em seguida o resultado do sensoriamento é analisado, se houver algum canal desocupado é escolhido um canal para realizar a transmissão. Se todos os canais forem sensorizados ocupados o SU entra em modo de espera. Caso a predição não aponte nenhum canal desocupado é escolhido um canal aleatório para o sensoriamento e caso desocupado o SU executa a transmissão, do contrário entra em modo espera. Depois do intervalo de transmissão ou espera o ciclo é reiniciado.

Neste trabalho é suposta a predição imperfeita, ou seja, o algoritmo de inferência possui uma probabilidade de predição errada P_p^e . Quando a predição é realizada para apenas um estado futuro, $F = 1$, e considerando apenas um canal, $P_{0(s)}$ indica a probabilidade da etapa de predição classificar um canal como ocioso:

$$P_{0(s)} = P(H_0) \left(1 - P_p^e\right) + P(H_1) P_p^e, \quad (4.3)$$

ou seja, é a soma entre a probabilidade de haver predição correta para o tráfego ocioso e a probabilidade de haver predição incorreta no caso do tráfego ocupado. Da mesma forma, $P_{1(s)}$ é a probabilidade de que o estágio de predição classifique um canal como ocupado:

$$P_{1(s)} = P(H_0) P_p^e + P(H_1) \left(1 - P_p^e\right), \quad (4.4)$$

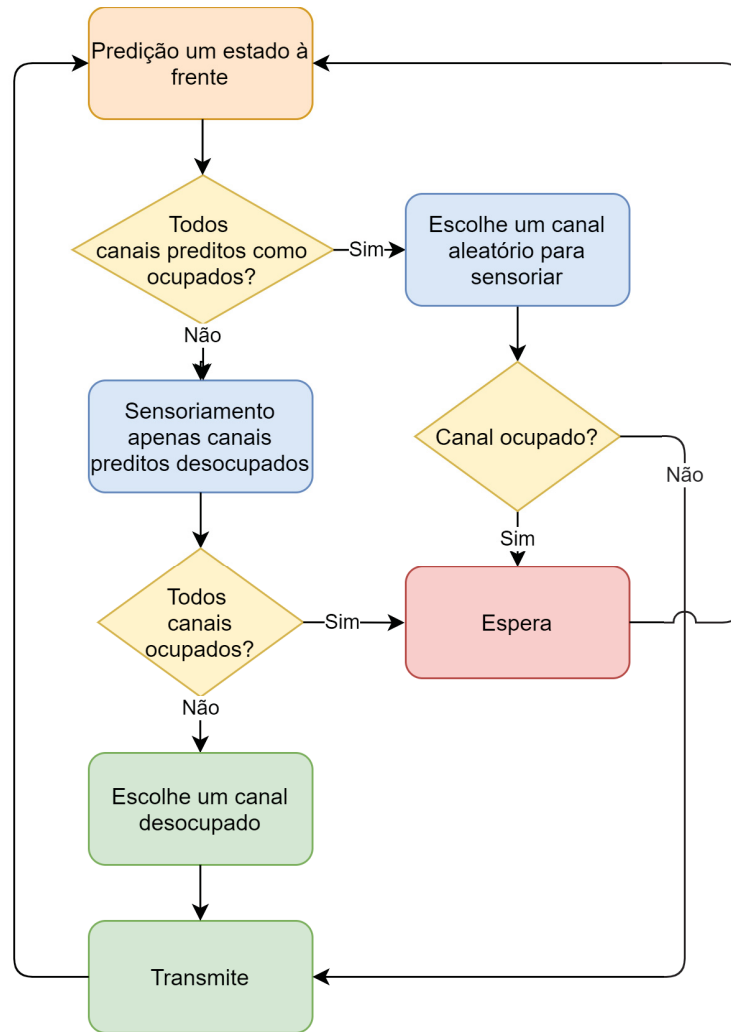


Figura 4.5: Algoritmo executado pelo SU com emprego de predição e sensoriamento (Yang e Zhao, 2015).

nesse caso, o resultado é a soma entre a probabilidade de haver predição incorreta para o tráfego ocioso e a probabilidade de haver predição correta no caso do tráfego ocupado.

Tabela 4.1: A distribuição de probabilidade do estado verdadeiro do canal e da predição (Yang e Zhao, 2015)

Estado verdadeiro do canal	Predição	Probabilidade
desocupado	desocupado	$P(H_0)(1 - P_p^e)$
desocupado	ocupado	$P(H_0)P_p^e$
ocupado	desocupado	$P(H_1)P_p^e$
ocupado	ocupado	$P(H_1)(1 - P_p^e)$

Ainda é possível montar a Tabela 4.1 que associa a predição e o estado verdadeiro do canal. De acordo com a literatura (Yang e Zhao, 2015) e detalhado na Figura 4.5, se houvesse apenas um canal disponível no cenário proposto, o total de probabilidades possíveis para sensoriamento, predição e estado verdadeiro do canal seriam: $(P_{0[q|1]}, P_{1[q|1]}, \dots, P_{7[q|1]})$. Resultando um total de $2^3 = 8$ possibilidades diferentes com probabilidades associadas, sendo calculadas por meio da Tabela 4.2.

Tabela 4.2: Probabilidades teóricas para sensoriamento, predição e estado verdadeiro do canal, supondo canal único ($N_C = 1$) e $F = 1$.

Estado Real	Predição	sensoriamento	Probabilidade
desocupado	desocupado	desocupado	$P_{0[q 1]} = \frac{(1-P_f)P(H_0)(1-P_p^e)}{P(H_0)(1-P_p^e)+P(H_1)P_p^e}$
desocupado	desocupado	ocupado	$P_{1[q 1]} = \frac{P_f P(H_0)(1-P_p^e)}{P(H_0)(1-P_p^e)+P(H_1)P_p^e}$
desocupado	ocupado	desocupado	$P_{2[q 1]} = \frac{(1-P_f)P(H_0)P_p^e}{P(H_0)P_p^e+P(H_1)(1-P_p^e)}$
desocupado	ocupado	ocupado	$P_{3[q 1]} = \frac{P_f P(H_0)P_p^e}{P(H_0)P_p^e+P(H_1)(1-P_p^e)}$
ocupado	desocupado	desocupado	$P_{4[q 1]} = \frac{(1-P_d)P(H_1)P_p^e}{P(H_0)(1-P_p^e)+P(H_1)P_p^e}$
ocupado	desocupado	ocupado	$P_{5[q 1]} = \frac{P_d P(H_1)P_p^e}{P(H_0)(1-P_p^e)+P(H_1)P_p^e}$
ocupado	ocupado	desocupado	$P_{6[q 1]} = \frac{(1-P_d)P(H_1)(1-P_p^e)}{P(H_0)P_p^e+P(H_1)(1-P_p^e)}$
ocupado	ocupado	ocupado	$P_{7[q 1]} = \frac{P_d P(H_1)(1-P_p^e)}{P(H_0)P_p^e+P(H_1)(1-P_p^e)}$

Como o cenário investigado contém múltiplos canais é necessário realizar o cálculo para a probabilidade de predição de toda a rede CR. Assumindo que existem exatamente k canais ociosos preditos entre os N_C canais licenciados, chega-se em um caso de teste de Bernoulli (distribuição binomial) com k repetições ($k \leq N_C$). A probabilidade de que k canais estejam ociosos, portanto segue a forma:

$$\binom{N_C}{k} (P_{0(s)})^k (P_{1(s)})^{(N_C-k)}. \quad (4.5)$$

Por fim, considerando todos os N_C canais, a probabilidade de predição que indica a disponibilidade da rede de possuir algum canal ocioso é a soma de todos os casos da expressão (4.5) (Yang e Zhao, 2015), dada por

$$P_{0(s|N_C)} = \sum_{k=1}^{N_C} \binom{N_C}{k} (P_{0(s)})^k (P_{1(s)})^{(N_C-k)}, \quad (4.6)$$

sendo que a probabilidade de todos os canais preditos estarem ocupados é

$$P_{1(s|N_C)} = \binom{N_C}{0} (P_{0(s)})^0 (P_{1(s)})^{(N_C-0)} = (P_{1(s)})^{N_C}. \quad (4.7)$$

Quando esse último evento acontece, o SU seleciona um canal aleatório para sensoriar, conforme já mencionado.

Uma outra forma de visualização das expressões (4.6) e (4.7) pode ser exemplificada por meio da Figura 4.6. A figura apresenta quatro canais e cada uma das linhas representa as possíveis combinações de predição de estados futuros para os quadros avaliados. Um dos estados possíveis para cada canal é desocupado, na figura representado por um quadro verde e com probabilidade de predição de $P_{0(s)}$. Outro estado possível para cada canal é ocupado, na figura representado por um quadro vermelho e com probabilidade de predição de $P_{1(s)}$. A

probabilidade total para cada uma das linhas da figura é obtida por meio da multiplicação das probabilidades de cada quadro. Por fim a probabilidade da expressão (4.6) é resultado da soma das quinze primeiras linhas onde existe pelo menos um dos canais preditos desocupados. A probabilidade apresentada na expressão (4.7) está representada na última linha da Figura 4.6.

Canais			
A	B	C	D
0	0	0	0
0	0	0	1
0	0	1	0
0	0	1	1
0	1	0	0
0	1	0	1
0	1	1	0
0	1	1	1
1	0	0	0
1	0	0	1
1	0	1	0
1	0	1	1
1	1	0	0
1	1	0	1
1	1	1	0
1	1	1	1

Figura 4.6: Exemplo para análise das expressões (4.6) e (4.7), composto por quatro canais e possíveis estados de predição, $F = 1$.

Após o estágio de predição, o SU realiza detecção de espectro apenas em canais preditos como ociosos. Assim, para a análise teórica levando em consideração o sensoriamento, predição e estado verdadeiro do canal, podem existir $2^3 = 8$ com valores apresentados na Tabela 4.3. A última coluna da Tabela 4.3 é obtida por meio da multiplicação da última coluna da Tabela 4.2 pelos valores obtidos por meio de (4.6) ou (4.7).

4.2.2 Análise para múltiplos passos à frente

Estendendo a análise do quadro com predição e sensoriamento para vários estados futuros ($F > 1$), obtêm-se uma generalização dos resultados encontrados. Por uma questão de simplicidade, primeiro foi considerado $F = 2$, ou seja, o algoritmo implementado no SU analisa apenas dois estados futuros e, em seguida, é apresentada a generalização para qualquer

Tabela 4.3: Probabilidades teóricas para sensoriamento, predição e estado verdadeiro do canal, supondo múltiplos canais ($N_C > 1$) e $F = 1$ (Yang e Zhao, 2015).

Estado Real	Predição	sensoriamento	Probabilidade
desocupado	desocupado	desocupado	$P_{0[q N_C]} = P_{0[q 1]} P_{0(s N_C)}$
desocupado	desocupado	ocupado	$P_{1[q N_C]} = P_{1[q 1]} P_{0(s N_C)}$
desocupado	ocupado	desocupado	$P_{2[q N_C]} = P_{2[q 1]} P_{1(s N_C)}$
desocupado	ocupado	ocupado	$P_{3[q N_C]} = P_{3[q 1]} P_{1(s N_C)}$
ocupado	desocupado	desocupado	$P_{4[q N_C]} = P_{4[q 1]} P_{0(s N_C)}$
ocupado	desocupado	ocupado	$P_{5[q N_C]} = P_{5[q 1]} P_{0(s N_C)}$
ocupado	ocupado	desocupado	$P_{6[q N_C]} = P_{6[q 1]} P_{1(s N_C)}$
ocupado	ocupado	ocupado	$P_{7[q N_C]} = P_{7[q 1]} P_{1(s N_C)}$

F . A Figura 4.7 introduz uma nova estrutura de quadro de SU, definida aqui como SU-M. Esse quadro é similar ao quadro evidenciado na Figura 4.4, o ciclo, no entanto, é modificado para incluir apenas uma etapa de predição com duração τ_P , seguida por F etapas de sensoriamento e transmissão ou espera em sequência. O quadro do SU-M também possui duração T , a etapa de sensoriamento possui duração τ_S e transmissão ou espera pode possuir duração $T - \tau_P - \tau_S$ ou $T - \tau_S$ dependendo dos eventos do ciclo do SU.




Figura 4.7: Quadro de operação SU-M para predição com múltiplos passos à frente, com duração T , dividido em três etapas: (i) τ_P predição, (ii) τ_S sensoriamento e (iii) transmissão ou espera com intervalo $T - \tau_S$ ou $T - \tau_P - \tau_S$

Para a análise de múltiplos passos à frente, mas analisando apenas um canal, a probabilidade de prever ambos os estados como ociosos é $P_{0(l)} = (P_{0(s)})^2$. A probabilidade de prever que o primeiro estado será ocioso e o próximo ocupado é $P_{1(l)} = (P_{0(s)}) (P_{1(s)})$. Da mesma forma, a probabilidade de prever o primeiro estado como ocupado e o próximo como ocioso é $P_{2(l)} = (P_{1(s)}) (P_{0(s)})$. Finalmente, a probabilidade de prever que ambos os estados estarão ocupados é $P_{3(l)} = (P_{1(s)})^2$.

É possível observar que existem $B = 2^F$ combinações diferentes de resultados de predição de ociosidade ou ocupação ao considerar F quadros futuros. Portanto $b \in \{0, 1, \dots, (B - 1)\}$ indica a representação decimal de uma combinação de resultados de predição de ociosidade ou ocupação. Por exemplo, considerando três quadros futuros, $b = 5$ significa que o resultado da predição é (ocupado, ocioso, ocupado), o que é representado pela sequência binária $\{101\}$. Então,

Tabela 4.4: Probabilidades teóricas para sensoriamento, predição e estado verdadeiro do canal, supondo canal único ($N_C = 1$) e $F = 2$.

Estado Real 1	Predição 1	sensoriamento 1	Estado Real 2	Predição 2	sensoriamento 2	Probabilidade
desocupado	desocupado	desocupado	desocupado	desocupado	desocupado	$P_{0[r 1]} = \frac{P_{0(l)}}{(1-P_f)P(H_0)(1-P_p^e)^2}$
desocupado	desocupado	desocupado	desocupado	desocupado	ocupado	$P_{1[r 1]} = \frac{P_{0(l)}}{((1-P_f)P(H_0)(1-P_p^e))(P_f P(H_0)(1-P_p^e))}$
desocupado	desocupado	desocupado	desocupado	ocupado	desocupado	$P_{2[r 1]} = \frac{P_{0(l)}}{((1-P_f)P(H_0)(1-P_p^e))(1-P_f)P(H_0)P_p^e}$
desocupado	desocupado	desocupado	desocupado	ocupado	ocupado	$P_{3[r 1]} = \frac{P_{0(l)}}{((1-P_f)P(H_0)(1-P_p^e))(P_f P(H_0)P_p^e)}$
desocupado	desocupado	desocupado	ocupado	desocupado	desocupado	$P_{4[r 1]} = \frac{P_{0(l)}}{((1-P_f)P(H_0)(1-P_p^e))(1-P_d)P(H_1)P_p^e}$
...
ocupado	ocupado	ocupado	ocupado	ocupado	ocupado	$P_{63[r 1]} = \frac{P_{3(l)}}{P_d P(H_1)(1-P_p^e)^2}$

para qualquer F , a probabilidade de uma combinação de resultado de predição de ocupado-ocioso para um canal, pode ser calculada como

$$P_{b(l)} = (P_{0(s)})^\theta (P_{1(s)})^\kappa, \quad b = \{0, 1, \dots, (B-1)\}, \quad (4.8)$$

onde θ é a quantidade de estados preditos desocupados e $\kappa = F - \theta$ é a quantidade de estados preditos como ocupados para a análise de apenas um canal.

Desta forma realizando a análise para vários estados futuros mas levando em consideração apenas um canal, é possível montar uma nova tabela com as probabilidades de predição, sensoriamento e estado verdadeiro que possuirá $\Psi = 2^{(F \cdot 3)}$ linhas e indicadas como $P_{0[r|1]}, P_{1[r|1]}, P_{\psi[r|1]} \dots P_{\Psi-1[r|1]}$. Tomando ainda o exemplo onde $F = 2$, $\Psi = 2^{(2 \cdot 3)} = 64$, é possível construir a Tabela 4.4

Agora, considerando os N_C canais e vários quadros futuros, a probabilidade de predição indicando a disponibilidade de canal, pode ser considerada como um experimento multinomial. Esse tipo de experimento consiste em um número N_C de tentativas, já que cada canal pode ser visto como independente um do outro. Cada tentativa pode resultar nas seguintes possibilidades de resultado para B : O_0, O_1, \dots, O_{B-1} . No exemplo anterior, considerando $F = 2$, os quatro resultados (ou eventos) possíveis são: $O_0 = \{00\}, O_1 = \{01\}, O_2 = \{10\}, O_3 = \{11\}$. As probabilidades $P_{0(l)}, P_{1(l)}, \dots, P_{B-1(l)}$ estão associadas a cada resultado possível. O vetor de peso $(k_0, k_1, \dots, k_{B-1})$ especifica o número de vezes que cada resultado O_b ocorre, de modo que $k_0 + k_1 + \dots + k_{B-1} = N_C$. A probabilidade associada a esse vetor é dada por:

$$P[(k_0, k_1, \dots, k_{B-1})] = \binom{N_C}{k_0, k_1, \dots, k_{B-1}} \prod_{b=0}^{(B-1)} (P_{b(l)})^{k_b}, \quad (4.9)$$

onde,

$$\binom{N_C}{k_0, k_1, \dots, k_{B-1}} = \frac{N_C!}{k_0! k_1! \dots k_{B-1}!}, \quad (4.10)$$

é o coeficiente multinomial. É possível observar que essa é a probabilidade de que O_0 ocorra k_0 vezes, O_1 ocorra k_2 vezes, \dots , e O_{B-1} ocorra k_{B-1} vezes.

Por exemplo, considerando $N_C = 3$ e $F = 2$, ou seja, três canais na rede CR e predição com dois estados futuros, o vetor de peso tem quatro elementos (k_0, k_1, k_2, k_3) e um valor possível para o vetor poderia ser $(2, 1, 0, 0)$ pois $2 + 1 + 0 + 0 = 3$. Isso significa que O_0 ocorre duas vezes, O_1 ocorre uma vez e não há ocorrências para O_2 e O_3 . A probabilidade desse evento é dada por:

$$\begin{aligned} P[(2, 1, 0, 0)] &= \binom{3}{2, 1, 0, 0} \prod_{b=0}^{(3)} (P_{b(l)})^{k_b} \\ &= \frac{3!}{2!1!0!0!} (P_{0(l)})^2 (P_{1(l)}) \\ &= 3(P_{0(l)})^2 (P_{1(l)}). \end{aligned} \quad (4.11)$$

Ao contrário do cálculo de predição para toda a rede CR com um estado futuro, para o qual a probabilidade é modelada por meio de uma distribuição binomial, a predição de disponibilidade de canal para toda a rede CR, em conjunto com a análise de vários estados futuros, é baseada em um modelo de distribuição multinomial. Desse modo, a probabilidade de predição que indica a disponibilidade de haver canais ociosos em toda a rede composta por N_C canais é uma soma de probabilidades no formato da expressão (4.11) apresentada acima. Ao realizar a análise para toda a rede CR composta por N_C canais, é obtida uma extensão do resultado apresentado em (Yang e Zhao, 2015). A equação generalizada para a probabilidade de toda a rede com vários canais estar ociosa em vários estados futuros é, portanto,

$$\begin{aligned} P_{0(l|N_C)} &= \sum_{k_0 \in \Phi} \sum_{k_1 \in \Phi} \cdots \sum_{k_{B-1} \in \Phi} P[(k_0, k_1, \dots, k_{B-1})], \\ \Phi &= \{k_0 + k_1 + \dots + k_{B-1} = N_C\}. \end{aligned} \quad (4.12)$$

A equação 4.12 leva em consideração todos os casos em que há probabilidade de predição de canais ociosos. A probabilidade de toda a rede estar predita ocupada é dada por

$$P_{1(l|N_C)} = 1 - P_{0(l|N_C)} \quad (4.13)$$

ou seja, é a probabilidade complementar de $P_{0(l|N_C)}$.

As expressões (4.12) e (4.13) podem ser analisadas por meio da Figura 4.8. A figura apresenta três canais e a predição é realizada para dois estados futuros ($F = 2$). Cada uma das linhas representa as possíveis combinações de predição de estados futuros para os quadros avaliados para todos os canais. Uma das combinações possíveis para cada canal é a predição de desocupação por dois estados futuros consecutivos, na figura representado por um quadro verde e com probabilidade de predição de $P_{0(l)}$. Outra combinação possível para cada canal é a predição do primeiro estado como desocupado e o segundo como ocupado, na figura representado por um quadro verde escuro e com probabilidade de predição de $P_{1(l)}$. Outra das combinações possíveis para cada canal é a predição de ocupado no primeiro estado futuro e desocupado no segundo

estado, na figura representado por um quadro laranja e com probabilidade de predição de $P_{2(l)}$. Por fim a última combinação possível para cada canal é a predição dos dois estados futuros como ocupados, na figura representado por um quadro verde escuro e com probabilidade de predição de $P_{3(l)}$. A probabilidade total para cada uma das linhas da figura é obtida por meio da multiplicação das probabilidades associadas de cada quadro, estas são indicadas por índices e apresentadas na Tabela 4.5. Por fim a probabilidade da expressão (4.6) é resultado da soma de todas as linhas onde existe pelo menos um dos canais preditos desocupados. A probabilidade apresentada na expressão (4.7) está representada na última linha da Figura 4.8.

Canais			
A	B	C	
0	0	0	a
0	0	1	b
0	0	2	c
0	0	3	d
0	1	0	e
0	1	1	f
0	1	2	g
0	1	3	h
0	2	0	i
0	2	1	j
0	2	2	k
0	2	3	l
...			
3	3	3	t

Figura 4.8: Exemplo para análise das expressões (4.6) e (4.7), composto por três canais e possíveis estados de predição, $F = 2$.

Tabela 4.5: Probabilidades associadas a Figura 4.8

Índice	Probabilidade
a	$\frac{3!}{3!0!0!0!} (P_{0(l)})^3$
b	$\frac{3!}{2!1!0!0!} (P_{0(l)})^2 (P_{1(l)})^1$
c	$\frac{3!}{2!0!1!0!} (P_{0(l)})^2 (P_{2(l)})^1$
t	$\frac{3!}{0!0!0!3!} (P_{3(l)})^3$

A análise para as probabilidades teóricas do estado verdadeiro do canal, predição e sensoriamento para $F = 2$ e para múltiplos canais, pode ser encontrada na Tabela 4.6, onde é possível verificar que a última coluna é a multiplicação da última coluna da Tabela 4.4 pelas equações 4.12 e 4.13.

Tabela 4.6: Probabilidades teóricas para sensoriamento, predição e estado verdadeiro do canal, supondo múltiplos canais ($N_C > 1$) e $F = 2$.

Estado Real 1	Predição 1	sensoriamento 1	Estado Real 2	Predição 2	sensoriamento 2	Probabilidade
desocupado	desocupado	desocupado	desocupado	desocupado	desocupado	$P_{0[r N_C]} = P_{0[r 1]}P_{0(l N_C)}$
desocupado	desocupado	desocupado	desocupado	desocupado	ocupado	$P_{1[r N_C]} = P_{1[r 1]}P_{0(l N_C)}$
desocupado	desocupado	desocupado	desocupado	ocupado	desocupado	$P_{2[r N_C]} = P_{2[r 1]}P_{1(l N_C)}$
desocupado	desocupado	desocupado	desocupado	ocupado	ocupado	$P_{3[r N_C]} = P_{3[r 1]}P_{1(l N_C)}$
desocupado	desocupado	desocupado	ocupado	desocupado	desocupado	$P_{4[r N_C]} = P_{4[r 1]}P_{0(l N_C)}$
...
ocupado	ocupado	ocupado	ocupado	ocupado	ocupado	$P_{63[r N_C]}P_{1(l N_C)}$

A taxa de transferência *throughput* de uma rede CR é definida como a quantidade total de dados transmitidos dividida pelo tempo total gasto. A análise segue a lógica proposta no Capítulo 2.1. Supondo o canal AWGN e a predição de apenas um estado futuro (quadro SU-P) se um canal estiver ocupado, o SU não transmitirá dados e a taxa de transferência será zero, ou seja, $C_{0|AWGN}^{SU-P} = 0$. Quando a rede CR opera na ausência de usuários primários o *throughput* máximo é indicado como, $C_{1|AWGN}^{SU-P} = \alpha^{SU-P} C_{1|AWGN}$. Quando o canal é detectado como ocioso, está ocupado pelo PU, $C_{2|AWGN}^{SU-P} = \alpha^{SU-P} C_{2|AWGN}$. Nesse caso,

$$C_{1|AWGN} = \log_2(1 + \gamma_S) \quad (4.14)$$

e,

$$C_{2|AWGN} = \log_2 \left(1 + \frac{\gamma_S}{1 + \gamma} \right). \quad (4.15)$$

O fator α^{SU-P} é dado por,

$$\alpha^{SU-P} = \frac{T - \tau_S - \tau_P}{T}. \quad (4.16)$$

Para o caso de múltiplos estados à frente, o fator α deve ser modificado conforme:

$$\alpha^{SU-M} = \frac{FT - F\tau_S - \tau_P}{FT}. \quad (4.17)$$

Assim,

$$C_{1|AWGN}^{SU-M} = \alpha^{SU-M} C_{1|AWGN}. \quad (4.18)$$

e

$$C_{2|AWGN}^{SU-M} = \alpha^{SU-M} C_{2|AWGN}. \quad (4.19)$$

Deste modo as expressões para a análise com um estado futuro devem ser entendidas como um caso especial das expressões obtidas para múltiplos estados futuros. O quadro SU-P pode ser visto também como um caso especial do quadro SU-M. Como a predição com múltiplos

passos à frente estima F estados no futuro, o estágio de predição não precisa ser executado mais de uma vez (figura 4.7), portanto, há um pequeno aumento na taxa de transferência da rede.

Para o canal *Rayleigh* o *throughput* do intervalo T completo, sem intervalos de sensoriamento ou predição (Rao, 2015) (Kuhn, 2006) será,

$$C_{1|Ray} = \log_2 e \cdot \exp\left(\frac{1}{\gamma_S}\right) \expint\left(\frac{1}{\gamma_S}\right), \quad (4.20)$$

e

$$C_{2|Ray} = \log_2 e \cdot \exp\left(\frac{(1+\gamma)}{\gamma_S}\right) \expint\left(\frac{(1+\gamma)}{\gamma_S}\right). \quad (4.21)$$

Portanto:

$$C_{1|Ray}^{SU-M} = \alpha^{SU-M} C_{1|Ray}, \quad (4.22)$$

e

$$C_{2|Ray}^{SU-M} = \alpha^{SU-M} C_{2|Ray}. \quad (4.23)$$

Para os canais AWGN ou Rayleigh o valor de *throughput* da rede, R , deve ser calculado utilizando a expressão:

$$R = \left(\sum_{\text{Sens}=0|\text{Real}=0} P_{i[r|N_C]} \right) C_1^{SU-M} + \left(\sum_{\text{Sens}=0|\text{Real}=1} P_{i[r|N_C]} \right) C_2^{SU-M}. \quad (4.24)$$

A expressão 4.24 pode ser escrita também como:

$$R = \alpha^{SU-M} r, \quad (4.25)$$

onde,

$$r = \left(\sum_{\text{Sens}=0|\text{Real}=0} P_{i[r|N_C]} \right) C_1 + \left(\sum_{\text{Sens}=0|\text{Real}=1} P_{i[r|N_C]} \right) C_2. \quad (4.26)$$

Respeitando em cada caso o *throughput* para cada canal, AWGN ou *Rayleigh*. A equação (4.24) pode ser normalizada para gerar valores adimensionais, ao realizar a sua divisão pelo limite superior $R_S = P(H_0)C_1^{SU-M} + P(H_1)C_2^{SU-M}$:

$$R_{Norm} = \frac{R}{R_S}. \quad (4.27)$$




Figura 4.9: Um exemplo de escolha de canais pelo SU. Havendo vários canais desocupados a escolha mais lógica para o SU é continuar utilizando o mesmo canal.

4.3 AGENDAMENTO DE CANAIS

O SU possui a capacidade de trocar de canal caso seja oportuno, no entanto, este procedimento gera um custo em termos de *throughput* (Zhang et al., 2014) devido ao tempo consumido pela troca de canais e de energia diante da reconfiguração de seus circuitos internos (Bayhan e Alagoz, 2012) (Chang et al., 2013). Até o presente, a etapa de troca de canal não foi considerada em conjunto com os esquemas de sensoriamento e de predição apresentados. Se a etapa de troca de canal for considerada, o SU deve evitar trocas desnecessárias e por isso é interessante realizar modificações nos esquemas já apresentados.

Primeiramente ao analisar o caso do quadro do SU-S com a análise de múltiplos canais é possível notar que o algoritmo apresentado na Figura 2.3(b) não define nenhum tipo de análise de canais sensoriados desocupados. Dessa forma, após transmitir por um determinado canal um novo ciclo é executado, se o mesmo canal for sensoriado desocupado e se nenhuma política for empregada para o uso inteligente de canal, o SU pode escolher outro canal desocupado para executar a transmissão. Assim, o mais lógico é implementar um esquema simples de persistência no mesmo canal caso esteja desocupado. Esse caso é ilustrado na Figura 4.9, onde são apresentados faixas do espectro em função do tempo. Na mesma Figura são indicados os instantes de ocupação do PU e as porções do espectro que estão livres para o uso do SU. Ao realizar o sensoriamento de múltiplos canais o SU deve realizar uma escolha de canal, sendo que a melhor opção nesse exemplo é manter o uso no mesmo canal.




Figura 4.10: O SU realiza trocas de canais que poderiam ter sido evitadas caso houvesse um planejamento antecipado.

Ao implementar o esquema de predição e sensoriamento, SU-P, o SU consegue realizar um sensoriamento seletivo em bandas que estão preditas desocupadas. No entanto, como a predição é repetida a cada ciclo, é possível cair em um caso de troca excessiva de canal conforme exemplificado na Figura 4.10. Nesse exemplo o SU consegue realizar de forma efetiva a predição, sensoriamento e ocupação em porções do espectro desocupadas para realizar a transmissão. Todavia, as escolhas ilustradas na Figura 4.10 apresentaram trocas de canal que poderiam ter sido evitadas caso o algoritmo implementado no SU tivesse conhecimento de quais bandas estariam desocupadas por uma quantidade maior de tempo. Nesse exemplo, o SU poderia ter escolhido o "Canal 1" que possui probabilidade de estar desocupado por uma quantidade maior de estados futuros e essa probabilidade é maior que dos outros canais.

4.3.1 Agendamento por quantidade de canais ociosos

O planejamento antecipado de canal é um esquema para evitar a troca de canais de forma desnecessária. Esse planejamento antecipado é definido neste trabalho como agendamento de canal. A solução para o problema descrito pelo exemplo da Figura 4.9 é realizada por meio da predição com múltiplos passos à frente. Ao realizar a predição com múltiplos passos, o SU vai inferir os canais livres em cada estado futuro. Os dados levantados podem então ser classificados em ordem de maior quantidade de estados ociosos sequenciais.

Os quadros do SU, já apresentados anteriormente, podem ser modificados para incluir o tempo gasto por troca da canal. Nesse caso serão indicados como SU-S', SU-P' ou SU-M'

para diferenciá-los dos quadros sem a análise de troca de canal. Os mesmos operam conforme mostrado na Figura 4.11(a), 4.11(b) e 4.11(c).

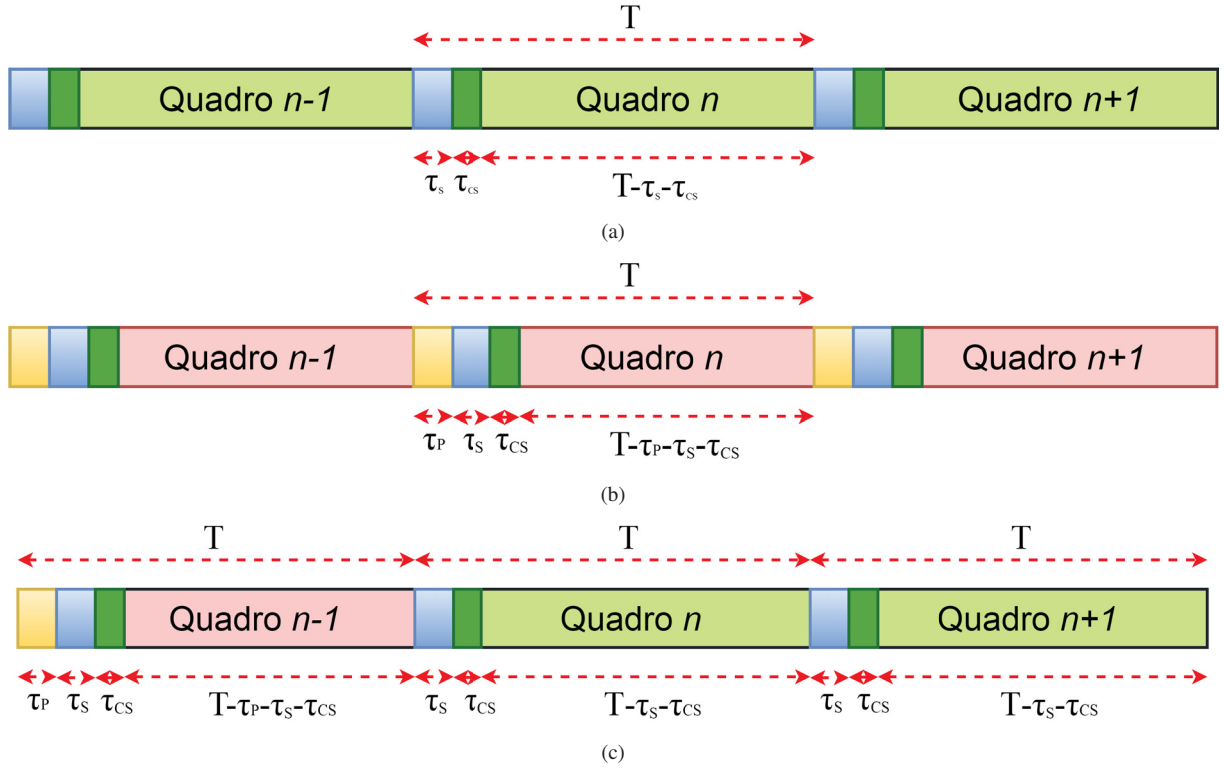


Figura 4.11: Quadros modificados com a etapa de troca de canal incluída (a) Quadro básico SU-S. (b) Quadro com previsão SU-P. (c) Quadro com previsão para múltiplos estados SU-M.

Os fatores de correção de *throughput*, α , são alterados no caso em que é realizada a troca de canal, conforme:

$$\alpha^{SU-S'} = \frac{T - \tau_s - \tau_{cs}}{T}, \quad (4.28)$$

$$\alpha^{SU-P'} = \frac{T - \tau_s - \tau_p - \tau_{cs}}{T}. \quad (4.29)$$

$$\alpha^{SU-M'} = \frac{FT - F\tau_s - \tau_p - F\tau_{cs}}{FT}. \quad (4.30)$$

O agendamento de canais é implementado no SU por meio de um algoritmo que visa minimizar a quantidade de troca de canais. Ao realizar a previsão com múltiplos passos à frente em um cenário com diferentes canais é possível realizar a ordenação dos canais que possuam a maior quantidade possível de estados futuros ociosos em sequência, \hat{u} . Depois dessa etapa, os canais preditos ociosos são sensoriados, no entanto, será eleito para transmissão aquele com precedência definida pelo esquema de agendamento proposto.

Em um cenário simplista com apenas dois canais, caso encontre um canal que possua todos os F estados ociosos e, um segundo canal que possua uma sequência de $F - 1$ estados

ociosos, sendo que apenas o último estado seja predito ocupado, ambos os canais são eleitos para o sensoriamento. O canal "A", no entanto, possui uma prioridade na escolha e caso ambos sejam sensoriados como desocupados esse será o escolhido pois possui a maior probabilidade de evitar a troca de canal.

O algoritmo proposto estipula apenas as trocas de canais realmente necessárias, ou seja, nos casos em que um canal possua uma quantidade de estados ociosos menor que a janela de predição, mas exista outro canal com disponibilidade a partir daquela posição de estado futuro (quebra na sequência de canais ociosos), é realizada uma nova análise de reordenamento e troca de escolha de prioridade.

Se o canal que possui prioridade de escolha for sensoriado como ocupado ele perde a prioridade de escolha e essa precedência é alterada para o canal definido pelo algoritmo como segundo colocado na lista de prioridades.

No algoritmo proposto, foi definida outra alteração para realizar uma otimização no sensoriamento com múltiplos passos à frente. Da lista de prioridades de transmissão o algoritmo permite escolher uma fração dentre os canais disponíveis para realizar o sensoriamento. Essa seleção diferenciada permite que o projetista possa ter controle na quantidade de canais que serão sensoriados pelo algoritmo preditor. O algoritmo permite um controle na redução de energia gasta no sensoriamento de canais e age de forma diferenciada do que é proposto no quadro SU-P (Yang e Zhao, 2015), onde o algoritmo realiza o sensoriamento em todos os canais preditos ociosos.

Portanto, dos N_C canais da rede, n_C canais são preditos ociosos por ciclo de predição e n_C^* são definidos pelo projetista para que o algoritmo efetue o sensoriamento.

$$n_C^* = \lfloor \omega N_C \rfloor, \quad (4.31)$$

onde $0 < \omega < 1$, e n_C^* é um inteiro sendo que $n_C^* \leq n_C \leq N_C$, n_C é variável e dependente do algoritmo preditor e N_C é a quantidade total de canais no cenário.

O algoritmo proposto que utiliza o quadro SU-M (predição para múltiplos estados à frente) e com agendamento de canais está descrito em pseudocódigo no Algoritmo 1. O mesmo será descrito de forma detalhada a seguir.

Primeiramente são definidas as variáveis de controle para o algoritmo, como quantidade de canais que serão avaliados, valores de projeto, valor da janela de predição e valor da janela de observação, entre outros. Na sequência, o modelo SVM do preditor deve ser submetido à fase de treinamento. Após essa etapa o algoritmo do SU está pronto para ser executado de forma efetiva.

O SU realiza a predição de F estados à frente (análise da janela de observação), essa predição com múltiplos passos à frente é realizada para N_C canais. O SU associa cada canal a sua respectiva quantidade de estados futuros livres sequenciais. O algoritmo analisa os canais que possuem estados futuros preditos desocupados começando por \hat{s}_η^{i+1} e realiza a ordenação

do canal com a maior sequência de canais ociosos para o canal que possui a menor quantidade. Desse modo é criada uma lista com a ordenação de canais preditos desocupados.

Caso a quantidade predita de canais ociosos para o canal com maior prioridade da lista seja inferior ao total da janela de predição (menor que F), e tenha último canal predito como \hat{s}_η^{i+n} , o algoritmo realiza uma nova análise para todos os canais, agora começando em \hat{s}_η^{i+n+1} . Uma nova lista de prioridades é definida pelo SU com validade a partir do estado \hat{s}_η^{i+n+1} . Mais listas podem ser criadas caso a mesma situação se repita.

Caso todos os canais sejam preditos como ociosos em um estado futuro, o algoritmo elege para sensoriamento o canal anteriormente utilizado para transmissão. Essa lógica também se baseia na tentativa de redução de trocas de canais de forma desnecessária.

Após realizado o sensoriamento apenas nos n_C^* canais definidos, o algoritmo pode efetuar de forma efetiva a transmissão caso o estado seja detectado como ocioso. O canal com maior precedência na primeira lista definida após a etapa de predição é escolhido para a transmissão. Caso esse seja sensoriado ocupado, a precedência muda para o próximo da lista e assim sucessivamente. Caso todos os canais sensoriados estejam ocupados, o SU não realiza transmissão e entra em modo de espera. O sensoriamento é realizado para os F estados futuros, sempre respeitando a quantidade de canais para sensoriamento n_C^* . O algoritmo observa se houve troca de lista de prioridades e caso exista outra lista, executa a prioridade de transmissão dessa nova lista. Após o sensoriamento nos F estados futuros, o algoritmo repete a etapa de predição com múltiplos estados futuros, reiniciando o ciclo.

Dessa maneira o algoritmo realiza um planejamento completo para todos os F estados futuros, e reduz ao máximo a quantidade desnecessária de trocas de canais. Ao realizar o planejamento antecipado de canais, a quantidade de intervalos de troca de canal τ_{CS} é reduzida.

Ao permitir que a quantidade de canais sensoriados seja reduzida de forma proposital ao definir n_C^* , o algoritmo gera uma economia em termos de energia expendida ao sensoriar múltiplas bandas.

Algoritmo 1 Algoritmo de funcionamento para o quadro SU-M

```

1: Define  $F, L, N_C, n_C^*$ 
2: for all  $\eta = 1, 2, \dots, N_C$  do
3:   encontra  $\hat{s}_\eta^F$ 
4:   for all  $\hat{s}_\eta^F = \hat{s}_1^F, \dots, \hat{s}_{N_C}^F$  do
5:     contaOciosos  $\leftarrow 0$ 
6:     lista  $\leftarrow 1$ 
7:     while contaOciosos  $< F$  do
8:       encontra  $\hat{s}_\eta^u$ 
9:       if  $\hat{s}_\eta^u \in \{\}$  then
10:        vetor.lista  $\leftarrow$  vetor.lista-1(1)
11:        lista++
12:        contaOciosos++
13:      else
14:        vetor.lista  $\leftarrow [\max(\hat{s}_\eta^u), \dots, \min(\hat{s}_\eta^u)]$ 
15:        lista++
16:        contaOciosos = contaOciosos + vetor.lista(1)
17:      end if
18:    end while
19:  end for
20:  lista  $\leftarrow 1$ 
21: end for
22: for all  $f = 1, 2, \dots, F$  do
23:   for all  $\eta^* = \text{vetor.lista}(1), \dots, \text{vetor.lista}(n_C^*)$  do
24:     sensoriamento no canal  $\eta^*$ 
25:     if  $\hat{s}_{\eta^*}^f = 0$  then
26:       transmite utilizando o canal  $\eta^*$ 
27:     else if  $\hat{s}_{\eta^*}^f = 1$  then
28:       não transmite no canal  $\eta^*$ , aguarda próximo sensoriamento, remove  $\eta^*$  de vetor.lista
29:     else if  $\hat{s}_{n_C^*}^f = 1$  then
30:       todos os canais sensorizados ocupados, não realiza transmissão
31:     end if
32:     if vetor.lista(1)  $< f$  then
33:       lista++
34:     end if
35:   end for
36: end for
=0

```

4.4 ANÁLISE DA EFICIÊNCIA ENERGÉTICA

A eficiência energética (EE) do SU é considerada nessa pesquisa como a razão entre *throughput* e energia devido ao cenário de rádio cognitivo (sensoriamento, predição e transmissão). Essa análise segue o que foi considerado na literatura sobre rádio cognitivo (Zhang et al., 2014), que é diferente de sistemas convencionais de comunicação sem fio que não envolvem detecção de espectro (Miao et al., 2008). A definição de EE aqui também possui a mesma finalidade das definições da literatura que é de realizar a quantificação do sistema de comunicação em termos de informação por energia (bits/Joule) sobre certa largura de banda. Desse modo:

$$EE = \frac{R}{\mathcal{E}} \text{ bits/Hz/Joule}, \quad (4.32)$$

onde R é calculado por meio da equação (4.25) e \mathcal{E} corresponde ao valor de energia média expendida para realizar a transmissão, sendo que esse valor depende de cada um dos quadros avaliados.

A potência de sensoriamento é indicada por \mathcal{P}_S . De forma lógica o gasto de energia é proporcional a quantidade de bandas de frequência sensoriadas. É suposto o sensoriamento multibanda em paralelo, ou seja, o detector de energia opera em paralelo (Hattab e Ibnkahla, 2014). Desse modo é possível indicar,

$$\mathcal{P}_S = \iota n_C^* W, \quad (4.33)$$

onde ι indica a potência para sensoriar uma faixa de largura de banda unitária (nessa pesquisa medida em mW/kHz), W indica da largura de banda e n_C^* é definido em (4.31). A potência de transmissão \mathcal{P}_T é composta pela soma entre potência do circuito e a potência do sinal (Miao et al., 2008) (Zhang et al., 2014). A potência de espera \mathcal{P}_E está associada ao gasto de energia enquanto esse se encontra no modo de não transmissão.

A energia média e a eficiência energética para o quadro SU-S' são calculadas de acordo com a Tabela 4.7

Tabela 4.7: Energia média e a eficiência energética para o quadro SU-S'.

Caso	\mathcal{E}	$EE = R/\mathcal{E}$
Sem troca de canal	$\frac{\mathcal{P}_S \tau_S + \mathcal{P}_T (T - \tau_S)}{T}$	$\frac{T - \tau_S}{\mathcal{P}_S \tau_S + \mathcal{P}_T (T - \tau_S)} r$
Com troca de canal	$\frac{\mathcal{P}_S \tau_S + \mathcal{P}_{CS} \tau_{CS} + \mathcal{P}_T (T - \tau_{CS} - \tau_S)}{T}$	$\frac{T - \tau_S - \tau_{CS}}{\mathcal{P}_S \tau_S + \mathcal{P}_{CS} \tau_{CS} + \mathcal{P}_T (T - \tau_{CS} - \tau_S)} r$
Espera	$\frac{\mathcal{P}_S \tau_S + \mathcal{P}_E (T - \tau_S)}{T}$	0

Gerando pôr fim a expressão de eficiência energética para o quadro SU-S':

$$EE_{SU-S'} = \left(p_T \frac{T - \tau_S}{\mathcal{P}_S \tau_S + \mathcal{P}_T (T - \tau_S)} + p_{CS} \frac{T - \tau_S - \tau_{CS}}{\mathcal{P}_S \tau_S + \mathcal{P}_{CS} \tau_{CS} + \mathcal{P}_T (T - \tau_{CS} - \tau_S)} \right) r, \quad (4.34)$$

onde p_T é a probabilidade de transmissão dos quadros sem necessidade de troca de canal e, p_{CS} é a probabilidade de transmissão dos quadros com troca de canal.

Ao analisar o quadro SU-P' é possível identificar o gasto de energia para predição, indicado como \mathcal{P}_P . A energia média e a eficiência energética para o quadro SU-P' são calculadas de acordo com a Tabela 4.8

Tabela 4.8: Energia média e a eficiência energética para o quadro SU-P'.

Caso	\mathcal{E}	$EE = R/\mathcal{E}$
Sem troca de canal	$\frac{\mathcal{P}_P\tau_P + \mathcal{P}_S\tau_S + \mathcal{P}_T(T - \tau_P - \tau_S)}{T}$	$\frac{T - \tau_P - \tau_S}{\mathcal{P}_P\tau_P + \mathcal{P}_S\tau_S + \mathcal{P}_T(T - \tau_P - \tau_S)}r$
Com troca de canal	$\frac{\mathcal{P}_P\tau_P + \mathcal{P}_S\tau_S + \mathcal{P}_{CS}\tau_{CS} + \mathcal{P}_T(T - \tau_P - \tau_S - \tau_{CS})}{T}$	$\frac{T - \tau_P - \tau_S - \tau_{CS}}{\mathcal{P}_P\tau_P + \mathcal{P}_S\tau_S + \mathcal{P}_{CS}\tau_{CS} + \mathcal{P}_T(T - \tau_P - \tau_S - \tau_{CS})}r$
Espera	$\frac{\mathcal{P}_P\tau_P + \mathcal{P}_S\tau_S + \mathcal{P}_E(T - \tau_P - \tau_S)}{T}$	0

A expressão de eficiência energética para o quadro SU-P' é, portanto:

$$EE_{SU-P'} = \left(p_T \frac{T - \tau_P - \tau_S}{\mathcal{P}_P\tau_P + \mathcal{P}_S\tau_S + \mathcal{P}_T(T - \tau_P - \tau_S)} + p_{CS} \frac{T - \tau_P - \tau_S - \tau_{CS}}{\mathcal{P}_P\tau_P + \mathcal{P}_S\tau_S + \mathcal{P}_{CS}\tau_{CS} + \mathcal{P}_T(T - \tau_P - \tau_S - \tau_{CS})} \right) r. \quad (4.35)$$

Por fim, a expressão de energia média e a eficiência energética para o quadro SU-M' são calculadas de acordo com a Tabela 4.9

Tabela 4.9: Energia média e a eficiência energética para o quadro SU-M'.

Caso	\mathcal{E}	$EE = R/\mathcal{E}$
Sem troca de canal	$\frac{\mathcal{P}_P\tau_P + \mathcal{P}_SF\tau_S + \mathcal{P}_T(FT - \tau_P - F\tau_S)}{FT}$	$\frac{FT - \tau_P - F\tau_S}{\mathcal{P}_P\tau_P + \mathcal{P}_SF\tau_S + \mathcal{P}_T(FT - \tau_P - F\tau_S)}r$
Com troca de canal	$\frac{\mathcal{P}_P\tau_P + \mathcal{P}_SF\tau_S + \mathcal{P}_{CS}F\tau_{CS} + \mathcal{P}_T(FT - \tau_P - F\tau_S - F\tau_{CS})}{FT}$	$\frac{FT - \tau_P - F\tau_S - F\tau_{CS}}{\mathcal{P}_P\tau_P + \mathcal{P}_SF\tau_S + \mathcal{P}_{CS}F\tau_{CS} + \mathcal{P}_T(FT - \tau_P - F\tau_S - F\tau_{CS})}r$
Espera	$\frac{\mathcal{P}_P\tau_P + \mathcal{P}_SF\tau_S + \mathcal{P}_E(FT - \tau_P - F\tau_S)}{FT}$	0

A expressão de eficiência energética para o quadro SU-M' é:

$$EE_{SU-M'} = \left(p_T \frac{FT - \tau_P - F\tau_S}{\mathcal{P}_P\tau_P + \mathcal{P}_SF\tau_S + \mathcal{P}_T(FT - \tau_P - F\tau_S)} + p_{CS} \frac{FT - \tau_P - F\tau_S - F\tau_{CS}}{\mathcal{P}_P\tau_P + \mathcal{P}_SF\tau_S + \mathcal{P}_{CS}F\tau_{CS} + \mathcal{P}_T(FT - \tau_P - F\tau_S - F\tau_{CS})} \right) r. \quad (4.36)$$

4.5 RESULTADOS

Neste trabalho, foi utilizado na fase de treinamento uma quantidade de $Tr = 1000 \text{ slots}$ de amostra, e na fase de validação a quantidade de $Sl = 30000 \text{ slots}$ de amostras por rodada de simulação, o mesmo valor usado em (Shahid et al., 2013). A separação entre o conjunto de treinamento e o conjunto de validação foi realizada selecionando os primeiros 1000 quadros

para treinamento e o restante dos quadros para a validação. Foram realizadas simulações de treinamento e avaliação, com excelentes resultados, que são apresentados a seguir. Cada SU foi treinado com um conjunto diferente de *slots* para evitar resultados viciados. Em todos os casos a quantidade de canais avaliados na rede CR é de $N_C = 10$.

Para as simulações que realizam a análise de *throughput*, foram utilizados os mesmos valores de projeto que aqueles já definidos na literatura (Yang e Zhao, 2015): $\hat{P}_f = 0,1$, $\hat{P}_d = 0,9$, $T = 100$ ms, $\tau_P = 5$ ms, $\tau_S = 2,5$ ms, $\tau_{SC} = 5$ ms. Também foi definido $\gamma_S = 20$ dB e $\gamma = -15$ dB, escolhidos também conforme (Yang e Zhao, 2015).




Figura 4.12: probabilidade de predição errada, P_p^e , em função da quantidade de pontos futuros F , para diferentes tipos de algoritmos de aprendizagem de máquina.

A técnica SVM foi escolhida após uma comparação extensa entre várias técnicas de ML. Quatro algoritmos de aprendizado de máquina foram comparados: k-vizinhos mais próximos (do inglês, *k-Nearest Neighbors* ou kNN) (Chen et al., 2011), Árvore de classificação (Soltani e Mutka, 2015), rede neural (Tumuluru et al., 2010) (Shahid et al., 2013) e SVM. A rede neural utilizada contém duas camadas escondidas, a primeira possui quinze neurônios e a segunda possui vinte neurônios. Os neurônios foram implementados com a função de ativação do tipo tangente hiperbólica. Cada algoritmo foi testado com um conjunto de dados utilizado neste trabalho. A Figura 4.12 mostra a probabilidade de predição errada, P_p^e , uma medida

de desempenho de predição. Essa quantidade é obtida comparando os valores dos resultados preditos e dados corretos gerados. A Figura mostra a probabilidade de predição errada P_p^e em função da quantidade de dados futuros F . Como esperado, o nível de incerteza sempre aumenta à medida que aumentamos a quantidade de pontos preditos, isso é conhecido como o problema de acumulação de erro. Na Figura pode-se observar que o algoritmo SVM oferece o melhor desempenho entre todos os demais algoritmos testados. Esse recurso do SVM ML é válido para todos os números testados de slots futuros. As técnicas de kNN e Árvore de Classificação foram 11% e 13% mais rápidas em comparação com o algoritmo SVM na fase de treinamento. A técnica de Rede Neural foi 16% mais lenta do que o algoritmo SVM na fase de treinamento. Na fase de predição, os algoritmos kNN e Árvores de Classificação foram 7% e 9% mais rápidos em comparação com a técnica SVM, enquanto a técnica de Rede Neural foi 4% mais lenta. O SVM ainda era a melhor opção, pois fornece a melhor precisão.




Figura 4.13: Probabilidade de predição errada, P_p^e , em função da densidade de tráfego ρ , para diferentes valores de F . Figura gerada a partir do modelo exponencial *on-off*.

O desempenho do preditor é medido pela probabilidade de predição errada P_p^e , conforme descrito na Seção 2.2. Na literatura foi possível encontrar um trabalho (Yang e Zhao, 2015) onde os autores usam dois cenários com P_p^e constante para diferentes valores de densidade de tráfego ρ . No presente trabalho, entretanto, foi mostrado que a probabilidade de predição errada P_p^e

depende da densidade do tráfego. Essa situação é ilustrada na Figura 4.13, onde P_p^e não é linear e os casos menos favoráveis correspondem a cenários com desvanecimento *Rayleigh* devido a maior variabilidade do canal. O aumento da densidade do tráfego sozinho leva a uma variação de aproximadamente 18% na probabilidade de predição incorreta.




Figura 4.14: probabilidade de predição errada, P_p^e , utilizando dados empíricos, em função da densidade de tráfego ρ , para diferentes valores de F .

A Figura 4.14 mostra a probabilidade de predição errada P_p^e medida utilizando o algoritmo SVM em função de diferentes valores de densidade de tráfego ρ . Nesse caso foram utilizados os valores reais da medição de dados empíricos (Wellens et al., 2009)(Wellens e Mähönen, 2010). Para gerar os valores obtidos o algoritmo SVM foi definido com *kernel* linear com $L = 15$ e $F = \{3,4,5\}$. Para cada banda foram utilizados uma quantidade de *slots* de treinamento $Tr = 1000$ e para validação $Sl = 30000$. Como cada banda possui uma característica de tráfego diferente devido às definições do órgão regulador foi possível observar que cada uma delas possui características de densidades de tráfego que se mantiveram estáticas pela duração das medições. Dessa forma para realizar uma análise do desempenho do algoritmo SVM para os dados reais foram utilizadas bandas diferentes para cada valor de ρ . As bandas foram selecionadas pela densidade de tráfego mais aproximada aos valores de densidade de tráfego com variação entre $0,1 \leq \rho \leq 0,9$. Para cada valor de ρ apresentado na Figura foi escolhido uma faixa de

banda do estudo de medição real. A relação entre densidade de tráfego aproximado e f'_c das bandas avaliadas são evidenciados na Tabela 4.10.

Realizando a análise da Figura 4.14 pode-se primeiramente observar que o algoritmo SVM gera excelentes valores de P_p^e medido para todos os valores de ρ avaliados. É possível observar uma semelhança com a Figura 4.13, ou seja, o desempenho do algoritmo preditor possui desempenho superior para valores extremos de ρ . O valor de P_p^e medido aumenta para os valores intermediários de ρ pois existe maior variação de estados de ocupação, aumentando a incerteza na entrada do modelo preditor. Desse modo pode-se chegar à mesma conclusão obtida por meio da análise realizada para predição imperfeita baseada no modelo *on-off*, ou seja, os valores de P_p^e são dependentes do tráfego ρ . Essa análise difere da literatura (Yang e Zhao, 2015), que emprega um P_p^e para toda a faixa de ρ , mas vai de acordo com outra referência na literatura (Agarwal et al., 2016). É possível observar similaridades entre as Figuras 4.13 e 4.14, que trazem um comportamento similar na variação de P_p^e . No entanto é possível observar que P_p^e é muito maior no segundo caso. Isso se deve ao fato da medição real possuir peculiaridades como correlação entre bandas próximas, variação sazonal intradiária e definição de bandas pelo órgão regulador. Mesmo possuindo um P_p^e moderado, o algoritmo SVM pode ser utilizado como um excelente preditor. Os valores de o modelo de tráfego *on-off* se tornam uma opção de interesse no uso de simulações computacionais devido a sua simplicidade.

Tabela 4.10: Relação entre densidade de tráfego aproximado e f'_c das bandas avaliadas (Wellens e Mähönen, 2010)

ρ aproximado	f'_c (MHz)
0,1	446,4
0,2	420,6
0,3	359,5
0,4	367,9
0,5	432,3
0,6	398,5
0,7	382,1
0,8	347,2
0,9	690,1

A Figura 4.15 mostra uma comparação da quantidade de saltos de canal com dois modelos de quadros, SU-P' e SU-M', nesse é empregado o algoritmo de agendamento de canais. Nesta simulação, foi utilizada uma janela de observação de $L = 10$, janela de predição de $F = 5$ e valores de densidade de tráfego variando de $\rho = 0,1$ a $\rho = 0,9$. Nesse caso o SU utiliza o algoritmo definido para escolher o canal com o maior número de *slots* ociosos futuros. Para valores baixos de ρ , a maioria dos canais está ociosa e, quando nenhum critério de decisão é utilizado pelo SU, há uma grande quantidade de trocas de canais. Quando o esquema de predição com múltiplos estados à frente é usado, o salto de canal é limitado para valores baixos de ρ e aumenta à medida que ρ aumenta. Para facilitar a interpretação, a quantidade de trocas de canais foi normalizada dividindo o número de trocas pelo número de *slots* analisados. Para $\rho = 0,6$,

houve uma economia de até 42% na quantidade de trocas de canais ao empregar o agendamento, e para $\rho = 0,5$ o percentual correspondente foi de 49%. Para a geração desta Figura e das subsequentes também foi considerado $N_C = 10$ e o preditor escolhido em todos os caso é SVM com *kernel* linear.




Figura 4.15: Comparação da quantidade de troca de canal em função da densidade de tráfego, ρ , para os quadros SU-P' e SU-M'.

A Figura 4.16 apresenta o *throughput* normalizado, R_{norm} em função da densidade de tráfego para um cenário AWGN. Nessa Figura é introduzida a comparação entre quadros SU-S e SU-S' e SU-P e SU-P'. Pode-se observar uma diferença sutil de desempenho ao ser considerada ou não a troca de canais. Esta análise têm por objetivo apenas mostrar que ao considerar a troca de canais existe uma perda no *throughput* da rede CR devido aos intervalos que ocorrem trocas de canais. Nesse caso foi suposto que $T = 100\text{ms}$, $\tau_S = 10\text{ms}$, $\tau_P = 10\text{ms}$ e $\tau_{CS} = 10\text{ms}$. Os valores simulados condizem com os valores das curvas teóricas.

A Figura 4.17 mostra o *throughput* normalizado R_{Norm} em função da densidade de tráfego para um cenário AWGN para diversos tipos de quadros. Nesse caso, foi considerada a troca de canal para todos os quadros avaliados. Foram utilizados dois valores de estados futuros $F = 3$ e $F = 5$. Em todas as simulações, foi considerado o mesmo valor para a janela




Figura 4.16: Comparação do *throughput* normalizado, R_{norm} , entre quadros avaliados supondo a troca de canal.

de observação ($L = 15$). Todas as simulações resultaram em curvas muito próximas das curvas teóricas. É possível observar aumento no *throughput* da rede quando é empregado o quadro SU-M' com o algoritmo de agendamento de canais em comparação com o quadro SU-P'. Houve um aumento de *throughput* de aproximadamente 4% para os casos com $F = 5$ e de aproximadamente 3% para os casos com $F = 3$. O esquema de predição com múltiplos passos à frente reduz a quantidade de intervalos de predição τ_P permitindo uma otimização na rede. Outra vantagem alcançada é a redução da quantidade de intervalos de troca de canal τ_{CS} ao empregar o esquema de agendamento. Quando o canal mais ocioso é escolhido, há menos interrupções devido à mudança de canal. No caso de $F = 1$, ou seja o quadro SU-P' é empregado, o algoritmo de agendamento dá preferência ao canal que foi utilizado no estado anterior, evitando interrupções, mas não consegue realizar uma análise a longo prazo e as trocas são mais frequentes. Ao utilizar o esquema SU-M' e conforme F aumenta, é possível observar uma perda no desempenho da predição. Esse fato ocorre pois ao aumentarmos a quantidade de estados futuros preditos a economia causada pelo intervalo de τ_P começa a se tornar imperceptível em comparação com a quantidade de quadros avaliados. Outro problema é que o valor medido de P_p^e aumenta de forma exponencial conforme F aumenta, um dos fatores desse problema está ao utilizar o preditor

multiclasses SVM. Quanto maior a quantidade de classes, existe maior probabilidade de erro pois as margens de separação de classes diminuem (o algoritmo SVM divide as classes por meio de linhas e margens em um hiperplano imaginário). Resultando, por fim, em uma interferência maior entre as classes.




Figura 4.17: *Throughput* normalizado R_{Norm} da rede CR para o cenário AWGN com $F = 3$ e $F = 5$.

A Figura 4.18 mostra o *throughput* como uma função da densidade de tráfego, nesse caso foi considerado o desvanecimento *Rayleigh*. Essa Figura está apresentando o *throughput* R ao invés do *throughput* normalizado R_{Norm} para evidenciar de forma gráfica o impacto do desvanecimento no sinal. Foram realizadas três simulações, na primeira foi considerado um quadro SU-P', nos outros dois casos foi escolhido o quadro SU-M' para $F = \{3, 5\}$. As curvas teóricas para o canal *Rayleigh* com base nessas propriedades também são apresentadas. Além disso, como na Figura 4.17, os resultados das simulações estão muito próximos das curvas teóricas. Novamente, o quadro modificado SU-M' e o agendamento de canais produziram, em conjunto, ganhos em termos de *throughput* mesmo no cenário com desvanecimento. Há um aumento de aproximadamente 2% para $\rho = 0,5$ com SU-M' para $F = 5$ em comparação com SU-M' com $F = 3$. Os ganhos na Figura 4.18 são menores do que aqueles na Figura 4.17 porque o canal *Rayleigh* está sujeito a uma degradação de sinal maior do que o canal AWGN, impactando diretamente o desempenho do preditor SVM.




Figura 4.18: *Throughput* da rede CR considerando o desvanecimento *Rayleigh*. São considerados os quadros SU-P e SU-M' com $F = \{3,5\}$.

A Figura 4.19 apresenta a EE, eficiência energética, em função da densidade de tráfego ρ , quando é utilizado o esquema SU-M' e algoritmo de agendamento de canais. Para gerar as simulações os valores de EE são baseados nas expressões (4.34), (4.35) e (4.36). Para essa simulação foram utilizados diferentes valores de τ_S , τ_P e τ_{CS} , sendo que em todos os casos foram utilizados o intervalo do quadro total como $T = 100\text{ms}$. Os valores de potência utilizados para gerar a simulação foram: $\mathcal{P}_T = 10\text{mW}$, $\mathcal{P}_{CS} = 3\text{mW}$, a potência gasta para sensoriar uma unidade de largura de banda (conforme expressão (4.33)) é $\iota = 0,01\text{mW/kHz}$ (Zhang et al., 2014), por fim $\mathcal{P}_\varphi = 10\text{mW}$. A largura de banda de um canal é igual a $W = 200\text{kHz}$.

O valor de canais a serem sensoriados é definido em projeto como uma fração da quantidade total N_C , como $n_C^* = 0,3 \cdot N_C = 3$. Dessa forma nem todos os canais preditos desocupados serão sensoriados, permitindo uma maior economia de energia no sensoriamento de canais.

As probabilidades p_T e p_{CS} (transmissão dos quadros sem necessidade de troca de canal e probabilidade de transmissão dos quadros com troca de canal respectivamente) foram mensuradas para cada valor de tráfego, ρ simulado. É possível observar um ganho em termos

de eficiência energética quando é empregado o esquema SU-M' em comparação com os outros quadros.




Figura 4.19: Eficiência energética EE em função da densidade de tráfego ρ para a rede CR para diversos quadros avaliados.

Ao utilizar os valores de $\tau_S = \tau_P = \tau_{CS} = 10\text{ms}$ a EE fica muito próxima para os valores de $\rho = 0,1$ e $\rho = 0,2$, nesses casos o esquema SU-S' mostra ser mais vantajoso pois consegue realizar mais transmissões gastando menos energia, como o quadro SU-S é mais simples e não possui etapa de predição, consegue realizar as transmissões com menos esforço. Conforme ρ aumenta é possível notar um aumento na EE proporcionado pelos esquemas dos outros quadros. A partir de $\rho = 0,3$ o quadro SU-S' não apresenta ser o mais vantajoso pois gera mais gasto em termos de sensoriamento e de trocas de canais para realizar a transmissão de forma efetiva.

Ao utilizar os valores de $\tau_S = \tau_P = 15\text{ms}$ e $\tau_{CS} = 10\text{ms}$ é possível notar o mesmo padrão para o caso anterior, os esquemas dos quadros SU-P' e SU-M' são mais vantajosos que o esquema do quadro SU-S'. Contudo, como os intervalos de sensoriamento e predição aumentaram a EE diminuiu para todos os casos simulados.

Já ao utilizar os valores de menores de intervalos como $\tau_S = \tau_{CS} = 2.5\text{ms}$ e $\tau_P = 5\text{ms}$ é possível notar um aumento de EE geral para todos os casos. Para todas as simulações o esquema proposto para SU-M' apresenta ganhos em termos de EE a partir de $\rho > 0,3$.

Primeiramente é possível observar a diferença que a redução dos intervalos de predição causa no desempenho da rede CR. O período de predição é reduzido no quadro SU-M' em comparação com o quadro SU-P'. O SU-S' também não possui esse intervalo e não gera um gasto para a predição. Dessa forma o SU-S' consegue superar em termos de EE o esquema SU-M'. Para as outras situações O SU-M' supera os outros esquemas. No melhor caso a EE aumentou cerca de 6%.

Em segundo lugar, ao utilizar o algoritmo de agendamento de canais, a quantidade de trocas desnecessárias é reduzida, a energia gasta com trocas também é reduzida gerando um uso adequado da ocupação dos canais e refletindo em uma economia de energia ao utilizar o esquema proposto.

Por fim, no quadro SU-P' o sensoriamento é realizado em todos os canais preditos ociosos e no quadro SU-M' é possível ajustar a quantidade de canais que podem ser sensoriados, limitando o sensoriamento para uma fração dos canais possíveis por meio da definição de $n_C^* = 3$, conforme expressão 4.31. Dessa maneira existe uma redução no gasto de energia do SU na etapa de sensoriamento.

O tempo gasto com a predição no caso $F > 1$ tende a ser maior que o caso onde $F = 1$, isso acontece devido a dois fatores. Primeiro, a complexidade do preditor SVM com múltiplas classes (utilizado para os casos onde $F > 1$) é maior se comparado com o preditor SVM com apenas duas classes (casos onde $F = 1$). Segundo, o algoritmo de agendamento que é implementado no SU possui mais etapas de execução, como pode ser analisado em 1. Ainda ao estudar o algoritmo descrito em 1, é possível observar que o mesmo é implementado em duas fases distintas: na etapa de sensoriamento e na etapa de predição. Portanto o tempo de execução do algoritmo impacta em ambos os intervalos: τ_P e τ_S . Foi observado por meio de medições que este aumento nos intervalos não é linear. Ao realizar uma comparação para o intervalo de predição para os casos $F = 1$ e $F = 3$ foi observado um aumento de 17% no tempo gasto na etapa de predição. No caso da comparação entre $F = 1$ e $F = 5$ este aumento foi de 23%. A comparação entre intervalos de sensoriamento no entanto apresentou diferenças mais discretas. Uma comparação para o intervalo de sensoriamento entre os casos $F = 1$ e $F = 3$ resultou em um aumento de 5% no tempo gasto na etapa de sensoriamento. No caso da comparação entre $F = 1$ e $F = 5$ este aumento foi de 7%. Ao gerar as Figuras 4.17 e 4.18, no entanto, foi escolhido manter os valores iguais ao estudo (Yang e Zhao, 2015) que estabeleceu $\tau_P = 5ms$ e $\tau_S = 2,5ms$ para todos os cenários. Estes valores foram escolhidos pois um dos estudos da literatura aponta que a fase de predição pode ocupar entre 2 – 15% do valor total do quadro do SU (Chen et al., 2011) e outro estudo apontou que esta ocupação varia entre 1 – 30% (Masonta et al., 2012) do intervalo total.

Para uma análise comparativa supondo uma diferença entre os tempos gastos dos intervalos de sensoriamento e predição para $F = 1$ e $F > 1$, é possível analisar a Figura 4.19. Nesta figura existem diferentes simulações para alguns valores de τ_S e τ_P que se encontram dentro dos intervalos propostos na literatura. É possível comparar curvas que empregam os

esquemas SU-S' e SU-M', supondo que os intervalos tanto de predição e de sensoriamento no primeiro esquema sejam menores que os valores empregados no segundo esquema. Desta forma os esquemas propostos nesta pesquisa ainda apresentam ganhos em termos de eficiência energética. Estes ganhos evidentemente são menores que se comparados aos casos onde os tempos entre intervalos se mantém iguais variando os esquemas de predição.

5 CONSIDERAÇÕES FINAIS

Esta pesquisa realizou uma investigação da predição espectral para rádios cognitivos. Por meio da análise de múltiplos estados à frente foi possível verificar ganhos em termos de *throughput* e de eficiência energética.

Explorando as aproximações das FDA das distribuições qui-quadrado central e qui-quadrado não central, foi possível obter novas aproximações da probabilidade de falso alarme, probabilidade de detecção, expressão de limite constante e número de amostras de projeto para o detector de energia. As aproximações propostas estão mais próximas das equações originais se comparadas à aproximação TLC, já utilizada na literatura. Ao contrário da abordagem TLC, que é usada para um grande número de amostras, as abordagens apresentadas também podem ser utilizadas para um número moderado de amostras. Foi evidenciado que o projeto com as novas expressões de limite constante é mais preciso em termos de probabilidade de falso alarme medido e probabilidade de detecção medida para diferentes valores de SNR. O *throughput* da rede cognitiva é aprimorado quando essas novas expressões são implementadas. O projeto baseado nas novas expressões de limiares constantes suporta maiores variações de ruído, apresentando assim maior estabilidade na detecção da energia medida.

Uma nova expressão analítica para probabilidade de detecção para canal *Rayleigh* foi derivada por meio de uma simplificação na análise para baixo SNR, dessa forma pode-se chegar a uma expressão com formato reduzido e com elevada similaridade a equação definida na literatura (Atapattu et al., 2011).

Como as equações apresentadas são simples, podem ser utilizadas em todos os dispositivos de rádio cognitivos que já utilizam o detector de energia com um algoritmo baseado na abordagem TLC. As equações de limite de projeto constantes apresentadas podem ser usadas como uma alternativa à abordagem TLC para casos que requerem grandes quantidades de amostras ($\hat{\gamma} \ll 0$ dB) e especialmente para casos que requerem uma quantidade moderada de amostras ($\hat{\gamma} \approx 0$ dB) como uma rede de sensores e comunicações em um regime de bloco de comprimento finito. Com o cálculo do número de amostras, é possível chegar a resultados mais precisos para o detector de energia.

O uso da técnica de predição SVM mostrou desempenho superior em termos de erro de predição ao realizar a comparação com outras técnicas de aprendizagem de máquina. Como a técnica SVM mostrou uma baixa probabilidade de erro de predição para múltiplos estados futuros, foi escolhida para a execução da predição no SU.

Foi possível verificar por meio de simulações que o erro de predição depende da densidade de tráfego do PU, isso se deve ao fato de que quanto mais denso ou mais esparsa for o tráfego, o modelo gerado pelo algoritmo de aprendizagem de máquina tende a diminuir a probabilidade de erro de predição. Nesses casos extremos o tráfego é mais estático (quantidade

menor de trocas entre estados de ocupação e ociosidade). Esse resultado é relevante pois existem trabalhos na literatura que estabelecem um valor fixo de probabilidade de erro de predição independente da variação da densidade de tráfego do PU.

O algoritmo SVM também foi utilizado para predição de dados reais de maneira satisfatória. Essa análise foi utilizada de forma geral nesse trabalho somente para uma avaliação inicial, indicando uma possibilidade de utilização do algoritmo SVM em cenários reais. A análise de dados reais requer uma investigação mais profunda, que depende das reservas de faixas de frequências pelos órgãos reguladores dos países, análise de correlação entre bandas entre outras particularidades, o que foge do escopo desta tese.

Uma nova abordagem para predição com múltiplos estados à frente foi apresentada, o quadro do SU foi também modificado para incluir uma etapa de intervalo de predição que é executada com menos frequência gerando uma economia para o SU em termos de *throughput* e energia. Além dos ganhos proporcionados apenas redução na quantidade de intervalos de predição, foi possível observar que a predição com múltiplos passos à frente pode ser utilizada pelo SU para realizar um planejamento antecipado do uso de canais. O quadro do SU foi novamente alterado para incluir a etapa de troca de canais. Ao não realizar um planejamento no uso de canais o SU pode realizar trocas desnecessárias, aumentando o gasto com *throughput* e com energia. Em um cenário multibanda, o agendamento de canais realiza uma ordenação nos canais com probabilidade de estarem ociosos por uma quantidade maior de estados futuros. Se após o sensoriamento multibanda o canal com precedência estiver desocupado, este será escolhido para a efetiva transmissão na rede CR. O algoritmo proposto realiza trocas de canais de forma seletiva e apenas em casos necessários. Além desses ganhos, ao realizar uma seleção de canais a serem sensoriados, é possível obter maiores ganhos em termos de energia, pois o SU reduz o gasto com sensoriamento de canais.

No entanto, a probabilidade de erro de predição medida tende a aumentar conforme existe um aumento na quantidade de estados futuros. Esse comportamento é intrínseco aos esquemas de predição pois a incerteza se torna acumulada. O algoritmo de predição SVM realiza uma predição multiclasse, ou seja, os resultados da predição estão separados em classes. Ao aumentar a quantidade de estados futuros a quantidade de classes aumenta, o espaço de separação entre cada classe (margens definidas pelo algoritmo SVM) se torna mais próximo havendo uma maior probabilidade de classificação incorreta. Dessa forma foi estabelecido nessa pesquisa uma análise de até $F = 7$ estados futuros.

5.1 TRABALHOS FUTUROS

As principais sugestões para pesquisas futuras podem ser divididas nas áreas de sensoriamento e predição.

Na área de sensoriamento as principais ideias incluem a extensão da análise das aproximações qui-quadrado central e não central do detector de energia levando em consideração

canais com desvanecimento. Nesse caso as probabilidades de detecção seriam alteradas e novas expressões para limiar de detecção e número de amostras poderiam ser encontradas. Outra possibilidade que tem sido analisada em alguns trabalhos na literatura são esquemas de detecção com múltiplos limiares. Nesses casos a estrutura do teste de hipóteses é alterado para modificar os limiares de detecção em busca de uma otimização nos resultados de sensoriamento. Um estudo aprofundado pode ser realizado levando em consideração as aproximações propostas neste trabalho em busca de resultados otimizados para o detector de energia com o emprego de pouco número de amostras.

Ainda na área de sensoriamento é interessante investigar o desempenho do detector de energia em conjunto com outras técnicas de detecção. O detector de energia clássico necessita de uma elevada quantidade de amostras em cenários com baixo SNR impactando diretamente na dinâmica da etapa de sensoriamento. O uso de outras técnicas em conjunto com o sensoriamento pode trazer benefícios para um sensoriamento acelerado e preciso. As análises das expressões do detector de energia podem ser baseadas nas aproximações apresentadas neste trabalho, pois também operam de forma acurada em ambientes com baixo SNR.

Um estudo de sensoriamento empírico foi utilizado neste trabalho com a finalidade de validar o modelo de predição utilizados. Não foi possível encontrar trabalhos que divulgassem dados de medições de sensoriamento em grandes faixas do espectro no Brasil. São poucos trabalhos na área de sensoriamento real que divulgam os dados coletados, esses apenas apresentam os resultados e conclusões nos artigos, sendo difícil encontrar bancos com dados coletados. Nesse contexto seria de interesse para a comunidade científica a realização de um estudo que apresentasse sensoriamento espectral em cidades brasileiras e também disponibilizasse os dados coletados de forma aberta.

Os dados apresentados na medição em campo na Europa apresentam características do espectro de frequências que são encontrados em muitos países, um cenário polarizado, onde muitas faixas do espectro são subutilizadas e possuem potencial para o uso oportunista do SU e outras faixas altamente utilizadas onde se torna difícil encontrar espaço para o uso do espectro. As agências reguladoras tendem a reservar faixas do espectro para aplicações que muitas vezes são raras. Essas faixas possuem o maior potencial para o emprego futuro de dispositivo cognitivo.

Na área de predição existem diversos campos que poderiam ser explorados em estudos futuros.

Primeiramente o maior desafio é a análise de técnicas de predição com múltiplos estados à frente. Novos estudos podem ser realizados levando em consideração a análise de múltiplos estados já que uma quantidade de trabalhos na comunidade científica tem se focado no estudo de predições para apenas um estado futuro. Técnicas mais simples também poderiam ser utilizadas pois possuem custo computacional mais baixo e poderiam trazer vantagens em termos de economia de energia e de *throughput*.

Outra sugestão de trabalhos futuros é a análise de predição com múltiplos estados futuros em um contexto cooperativo. A análise da rede CR com nós que atuam de forma cooperativa tem

sempre se mostrado vantajosa pois as análises conjuntas entre nós apresentam resultados mais precisos. Não foi encontrado na literatura nenhum trabalho que apresentasse uma análise que explorasse os ganhos obtidos por meio da predição de múltiplos estados com cooperação dos nós.

Uma outra suposição que não foi levantada e poderia ser investigada seria a implementação de um esquema de punição para canais que apresentam predição como desocupados mas são sensoriados como ocupados. Canais que apresentam maior diferença entre os valores sensoriados e os valores preditos são punidos e colocados em uma posição inferior nas listas de prioridade de transmissão.

Outra sugestão de trabalho futuro é a utilização de um esquema de *rendezvous* (Guerra et al., 2015) para a realização do encontro entre dispositivos SU nos canais escolhidos para transmissão, dessa forma o CCC seria eliminado da suposição escolhida nesse trabalho. A análise do esquema de *rendezvous* aumentaria a complexidade dos cenários mas evitaria que os dispositivos SU ficassem dependentes de um dispositivo de coordenação do CCC.

Conforme foi mostrado nesta tese, a análise da predição com múltiplos passos à frente pode trazer benefícios interessantes para a análise dos estudos de rádio cognitivo. Por meio da sua análise foi possível implementar um algoritmo de escolha de canais com a intenção de redução na quantidade de trocas de canais de forma desnecessária e evitando um gasto desnecessário em termos de energia. Do mesmo modo o quadro do SU pode ser alterado para aumentar o *throughput* da rede como um todo. Por fim a análise do sensoriamento mostrou que podem ser gerados ganhos para o SU ao implementar melhorias no sistema do detector de energia.

Ao aprofundar as análises nos esquemas de rádio cognitivo, são abertas possibilidades para diferentes modelos de aperfeiçoamento nos sistemas de comunicações sem fio. Essas possibilidades podem trazer juntamente consigo uma complexidade para os sistemas, fazendo com que essa área do conhecimento se torne um campo de pesquisa desafiador. Ao realizar a investigação da predição espectral para sistemas de rádio cognitivo utilizando análises com múltiplos estados à frente, foi possível chegar a resultados otimizados. Esta pesquisa trouxe contribuições que podem ser examinadas por outras perspectivas em pesquisas futuras. O estudo contínuo de técnicas eficientes para utilização do espectro abre espaço para que novos modelos práticos de rádio cognitivo sejam implementados em novas gerações de sistemas de comunicações sem fio.

REFERÊNCIAS

- Abdel-Aty, S. (1954). Approximate formulae for the percentage points and the probability integral of the non-central χ^2 distribution. *Biometrika*, 41(3/4):538–540.
- Abramowitz, M. e Stegun, I. A. (1970). *Handbook of mathematical functions with formulas, graphs, and mathematical tables*, volume 55. US Government printing office.
- Adas, A. (1997). Traffic models in broadband networks. *IEEE communications Magazine*, 35(7):82–89.
- Agarwal, A., Dubey, S., Khan, M. A., Gangopadhyay, R. e Debnath, S. (2016). Learning based primary user activity prediction in cognitive radio networks for efficient dynamic spectrum access. Em *2016 International Conference on Signal Processing and Communications (SPCOM)*, páginas 1–5. IEEE.
- Al-Anazi, A. e Gates, I. (2010). Support vector regression for porosity prediction in a heterogeneous reservoir: A comparative study. *Computers & Geosciences*, 36(12):1494–1503.
- Alkady, M. S., Abd-Elnaby, M., El-Dolil, S. A. e Abd El-Samie, F. E. (2019). An adaptive sensing time based on snr for spectrum utilization enhancement in cognitive radio. *Wireless Personal Communications*, 106(2):307–319.
- Allwein, E. L., Schapire, R. E. e Singer, Y. (2000). Reducing multiclass to binary: A unifying approach for margin classifiers. *Journal of machine learning research*, 1(Dec):113–141.
- Atapattu, S., Tellambura, C. e Jiang, H. (2011). Spectrum sensing via energy detector in low snr. Em *2011 IEEE International Conference on Communications (ICC)*, páginas 1–5. IEEE.
- Atapattu, S., Tellambura, C. e Jiang, H. (2014). *Energy detection for spectrum sensing in cognitive radio*, volume 6. Springer.
- Baldo, N. e Zorzi, M. (2008). Learning and adaptation in cognitive radios using neural networks. Em *2008 5th IEEE Consumer Communications and Networking Conference*, páginas 998–1003. IEEE.
- Barnes, S. D., Maharaj, B. T. e Alfa, A. S. (2016). Cooperative prediction for cognitive radio networks. *Wireless Personal Communications*, 89(4):1177–1202.
- Bayhan, S. e Alagoz, F. (2012). Scheduling in centralized cognitive radio networks for energy efficiency. *IEEE Transactions on Vehicular Technology*, 62(2):582–595.

- Bkassiny, M., Li, Y. e Jayaweera, S. K. (2012). A survey on machine-learning techniques in cognitive radios. *IEEE Communications Surveys & Tutorials*, 15(3):1136–1159.
- Cadena Muñoz, E., Pedraza Martínez, L. F. e Ortiz Triviño, J. E. (2020). Detection of malicious primary user emulation based on a support vector machine for a mobile cognitive radio network using software-defined radio. *Electronics*, 9(8):1282.
- Chandrasekaran, B. (2009). Survey of network traffic models. *Washington University in St. Louis CSE*, 567.
- Chang, P.-H., Chang, K.-F., Chen, Y.-C. e Ye, L.-K. (2013). Performance analysis of channel switching with various bandwidths in cognitive radio. Em *Proceedings of 12th International Conference on Networks, Seville*, volume 27, páginas 29–33.
- Cheema, A. A. e Salous, S. (2019). Spectrum occupancy measurements and analysis in 2.4 ghz wlan. *Electronics*, 8(9):1011.
- Chen, Z., Guo, N., Hu, Z. e Qiu, R. C. (2011). Channel state prediction in cognitive radio, part ii: Single-user prediction. Em *2011 Proceedings of IEEE Southeastcon*, páginas 50–54. IEEE.
- Ding, G., Jiao, Y., Wang, J., Zou, Y., Wu, Q., Yao, Y.-D. e Hanzo, L. (2017). Spectrum inference in cognitive radio networks: Algorithms and applications. *IEEE Communications Surveys & Tutorials*, 20(1):150–182.
- Ding, G., Wang, J., Wu, Q., Yao, Y.-D., Li, R., Zhang, H. e Zou, Y. (2015). On the limits of predictability in real-world radio spectrum state dynamics: From entropy theory to 5g spectrum sharing. *IEEE Communications Magazine*, 53(7):178–183.
- Drucker, H., Burges, C. J., Kaufman, L., Smola, A. J. e Vapnik, V. (1997). Support vector regression machines. Em *Advances in neural information processing systems*, páginas 155–161.
- El Morabit, Y., Mrabti, F. e Abarkan, E. H. (2015). Spectrum allocation using genetic algorithm in cognitive radio networks. Em *2015 Third International Workshop on RFID And Adaptive Wireless Sensor Networks (RAWSN)*, páginas 90–93. IEEE.
- Eltholth, A. (2015). Forward backward autoregressive spectrum prediction scheme in cognitive radio systems. Em *2015 9th International Conference on Signal Processing and Communication Systems (ICSPCS)*, páginas 1–5. IEEE.
- Eltholth, A. A. (2016). Spectrum prediction in cognitive radio systems using a wavelet neural network. Em *2016 24th International Conference on Software, Telecommunications and Computer Networks (SoftCOM)*, páginas 1–6. IEEE.

- Eltom, H., Kandeepan, S., Liang, Y. C., Moran, B. e Evans, R. J. (2016). Hmm based cooperative spectrum occupancy prediction using hard fusion. Em *2016 IEEE International Conference on Communications Workshops (ICC)*, páginas 669–675. IEEE.
- Fisher, R. A. (1922). On the interpretation of χ^2 from contingency tables, and the calculation of p. *Journal of the Royal Statistical Society*, 85(1):87–94.
- Ghazizadeh, E., Abbasi-moghadam, D. e Nezamabadi-pour, H. (2019). An enhanced two-phase svm algorithm for cooperative spectrum sensing in cognitive radio networks. *International Journal of Communication Systems*, 32(2):e3856.
- Godugu, K. K., Nallagonda, A. K. e Nallagonda, S. (2020). Performance of energy-efficient cooperative cognitive radio system over erroneous nakagami-m and weibull fading channels. *Wireless Networks*, 26(4):2623–2638.
- Goldsmith, A. (2005). *Wireless communications*. Cambridge university press.
- Gradshteyn, I. S. e Ryzhik, I. M. (2014). *Table of integrals, series, and products*. Academic press.
- Group, I. . W. et al. (2011). Ieee standard for wireless regional area networks part 22: cognitive wireless ran medium access control (mac) and physical layer (phy) specifications: policies and procedures for operation in the tv bands. *IEEE Standard*, 802.
- Guerra, E. O., Reguera, V. A., Souza, R. D., Fernández, E. G. e Pellenz, M. E. (2015). Systematic construction of common channel hopping rendezvous strategies in cognitive radio networks. *EURASIP Journal on Wireless Communications and Networking*, 2015(1):134.
- Guo, J., Ji, H., Li, Y. e Li, X. (2011). A novel spectrum handoff management scheme based on svm in cognitive radio networks. Em *2011 6th International ICST Conference on Communications and Networking in China (CHINACOM)*, páginas 645–649. IEEE.
- Gupta, A. e Majumder, S. (2019). Cognitive radio spectrum classification using fla-svm. Em *2019 9th Annual Information Technology, Electromechanical Engineering and Microelectronics Conference (IEMECON)*, páginas 144–149. IEEE.
- Hattab, G. e Ibnkahla, M. (2014). Multiband spectrum access: Great promises for future cognitive radio networks. *Proceedings of the IEEE*, 102(3):282–306.
- Hoang, A. T., Liang, Y.-C., Wong, D. T. C., Zeng, Y. e Zhang, R. (2009). Opportunistic spectrum access for energy-constrained cognitive radios. *IEEE Transactions on Wireless Communications*, 8(3):1206–1211.
- Hou, L., Yeung, K.-H. e Wong, K.-Y. (2014). Link availability prediction for cognitive radio ad hoc networks. *Journal of Computer and Communications*, 2014.

- Jain, S. e Goel, A. (2017). A survey of spectrum prediction techniques for cognitive radio networks. *International Journal of Applied Engineering Research*, 12(10):2196–2201.
- Johnson, N. L., Kotz, S. e Balakrishnan, N. (1995a). *Continuous univariate distributions, volume 1*. John Wiley & Sons, Ltd.
- Johnson, N. L., Kotz, S. e Balakrishnan, N. (1995b). *Continuous univariate distributions, volume 2*. John Wiley & Sons, Ltd.
- Kuhn, V. (2006). *Wireless communications over MIMO channels: applications to CDMA and multiple antenna systems*. John Wiley & Sons.
- Kumar, A., Thakur, P., Pandit, S. e Singh, G. (2019). Analysis of optimal threshold selection for spectrum sensing in a cognitive radio network: an energy detection approach. *Wireless Networks*, 25(7):3917–3931.
- Liang, Y.-C., Zeng, Y., Peh, E. C. e Hoang, A. T. (2008). Sensing-throughput tradeoff for cognitive radio networks. *IEEE transactions on Wireless Communications*, 7(4):1326–1337.
- Lin, Z., Jiang, X., Huang, L. e Yao, Y. (2009). A energy prediction based spectrum sensing approach for cognitive radio networks. Em *2009 5th International Conference on Wireless Communications, Networking and Mobile Computing*, páginas 1–4. IEEE.
- Masonta, M. T., Mzyece, M. e Ntlatlapa, N. (2012). Spectrum decision in cognitive radio networks: A survey. *IEEE Communications Surveys & Tutorials*, 15(3):1088–1107.
- Matias, R., Carvalho, A. M., Teodoro, V. A., Tes, D. e Araujo, L. B. (2011). Performance comparison of forecasting models applied to lan/man traffic prediction. Em *2011 18th IEEE Workshop on Local & Metropolitan Area Networks (LANMAN)*, páginas 1–6. IEEE.
- Miao, G., Himayat, N., Li, Y. e Bormann, D. (2008). Energy efficient design in wireless ofdma. Em *2008 IEEE International Conference on Communications*, páginas 3307–3312. IEEE.
- Mitola, J. e Maguire, G. Q. (1999). Cognitive radio: making software radios more personal. *IEEE personal communications*, 6(4):13–18.
- Murty, M. S. (2018). *Hardware-Efficient and Reconfigurable VLSI Architectures & Techniques for Spectrum Sensing in Cognitive Radio Wireless Networks*. Tese de doutorado, International Institute of Information Technology Hyderabad.
- Ni, S. e Shen, S. (2011). Frequency spectrum access mechanism of cognitive radio based on spectrum prediction.
- Ozcan, G. e Gursoy, M. C. (2013). Throughput of cognitive radio systems with finite blocklength codes. *IEEE Journal on Selected Areas in Communications*, 31(11):2541–2554.

- Ozden, M. T. (2013). Adaptive multichannel sequential lattice prediction filtering method for arma spectrum estimation in subbands. *EURASIP Journal on Advances in Signal Processing*, 2013(1):9.
- Rao, K. D. (2015). *Channel coding techniques for wireless communications*. Springer.
- Saad, A., Staehle, B. e Knorr, R. (2016). Spectrum prediction using hidden markov models for industrial cognitive radio. Em *2016 IEEE 12th International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob)*, páginas 1–7. IEEE.
- Sankaran, M. (1963). Approximations to the non-central chi-square distribution. *Biometrika*, 50(1/2):199–204.
- Sapankevych, N. I. e Sankar, R. (2009). Time series prediction using support vector machines: a survey. *IEEE Computational Intelligence Magazine*, 4(2):24–38.
- Shahid, A., Aslam, S., Kim, H. S. e Lee, K.-G. (2013). Csit: channel state and idle time predictor using a neural network for cognitive lte-advanced network. *Eurasip Journal on Wireless Communications and Networking*, 2013(1):203.
- Soltani, S. e Mutka, M. W. (2015). A decision tree cognitive routing scheme for cognitive radio mesh networks. *Wireless Communications and Mobile Computing*, 15(10):1405–1417.
- Stolojescu-Crisan, C. (2012). Data mining based wireless network traffic forecasting. Em *2012 10th International Symposium on Electronics and Telecommunications*, páginas 115–118. IEEE.
- Tang, L., Chen, Y., Hines, E. L. e Alouini, M.-S. (2011). Effect of primary user traffic on sensing-throughput tradeoff for cognitive radios. *IEEE Transactions on Wireless Communications*, 10(4):1063–1068.
- Tavana, M., Rahmati, A., Shah-Mansouri, V. e Maham, B. (2016). Cooperative sensing with joint energy and correlation detection in cognitive radio networks. *IEEE Communications Letters*, 21(1):132–135.
- Tumuluru, V. K., Wang, P. e Niyato, D. (2010). A neural network based spectrum prediction scheme for cognitive radio. Em *2010 IEEE International Conference on Communications*, páginas 1–5. IEEE.
- Urkowitz, H. (1967). Energy detection of unknown deterministic signals. *Proceedings of the IEEE*, 55(4):523–531.
- Vapnik, V. e Lerner, A. Y. (1963). Recognition of patterns with help of generalized portraits. *Avtomat. i Telemekh*, 24(6):774–780.

- Wan, R., Ding, L., Xiong, N., Shu, W. e Yang, L. (2019). Dynamic dual threshold cooperative spectrum sensing for cognitive radio under noise power uncertainty. *Human-centric Computing and Information Sciences*, 9(1):22.
- Wang, N., Gao, Y., Yang, F., Bi, Q., Xie, W. e Parini, C. (2017). Energy detection-based spectrum sensing with constraint region in cognitive lte systems. *Transactions on Emerging Telecommunications Technologies*, 28(11):e3171.
- Wang, Y., Zhang, Z., Ma, L. e Chen, J. (2014). Svm-based spectrum mobility prediction scheme in mobile cognitive radio networks. *The Scientific World Journal*, 2014.
- Wang, Z. e Salous, S. (2011). Spectrum occupancy statistics and time series models for cognitive radio. *Journal of signal processing systems*, 62(2):145–155.
- Wellens, M. e Mähönen, P. (2009). Rwth aachen university static spectrum occupancy measurement campaign. <https://download.mobnets.rwth-aachen.de/>. Acessado em 04/01/2021.
- Wellens, M. e Mähönen, P. (2010). Lessons learned from an extensive spectrum occupancy measurement campaign and a stochastic duty cycle model. *Mobile networks and applications*, 15(3):461–474.
- Wellens, M., Riihijärvi, J. e Mähönen, P. (2009). Empirical time and frequency domain models of spectrum use. *Physical Communication*, 2(1-2):10–32.
- Wen, Z., Luo, T., Xiang, W., Majhi, S. e Ma, Y. (2008). Autoregressive spectrum hole prediction model for cognitive radio systems. Em *ICC Workshops-2008 IEEE International Conference on Communications Workshops*, páginas 154–157. IEEE.
- Wilson, E. B. e Hilferty, M. M. (1931). The distribution of chi-square. *proceedings of the National Academy of Sciences of the United States of America*, 17(12):684.
- Wong, L. J., Clark IV, W. H., Flowers, B., Buehrer, R. M., Michaels, A. J. e Headley, W. C. (2020). The rfml ecosystem: A look at the unique challenges of applying deep learning to radio frequency applications. *arXiv preprint arXiv:2010.00432*.
- Xing, X., Jing, T., Cheng, W., Huo, Y. e Cheng, X. (2013). Spectrum prediction in cognitive radio networks. *IEEE Wireless Communications*, 20(2):90–96.
- Yang, J. e Zhao, H. (2015). Enhanced throughput of cognitive radio networks by imperfect spectrum prediction. *IEEE Communications Letters*, 19(10):1738–1741.
- Yarkan, S. e Arslan, H. (2007). Binary time series approach to spectrum prediction for cognitive radio. Em *2007 IEEE 66th vehicular technology conference*, páginas 1563–1567. IEEE.

- Yu, C.-J., He, Y.-Y. e Quan, T.-F. (2008). Frequency spectrum prediction method based on emd and svr. Em *2008 Eighth International Conference on Intelligent Systems Design and Applications*, volume 3, páginas 39–44. IEEE.
- Zhang, J., Zheng, F.-C., Gao, X.-Q. e Zhu, H.-B. (2014). Sensing-energy efficiency tradeoff for cognitive radio networks. *IET Communications*, 8(18):3414–3423.
- Zhang, S., Zhao, H., Wang, S. e Hafid, A. S. (2017). Impact of access contention on cooperative sensing optimisation in cognitive radio networks. *IET Communications*, 11(1):94–103.
- Zhang, Z., Zhang, K., Gao, F. e Zhang, S. (2015). Spectrum prediction and channel selection for sensing-based spectrum sharing scheme using online learning techniques. Em *2015 IEEE 26th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC)*, páginas 355–359. IEEE.